

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE CIÊNCIAS AGRONÔMICAS
CAMPUS DE BOTUCATU

**GEOESTATÍSTICA, SIMULAÇÃO ESTOCÁSTICA E
SENSORIAMENTO REMOTO NA ESTIMATIVA DE PRODUÇÃO DO
CAFÉ CONILON**

WAYLSON ZANCANELLA QUARTEZANI

Tese apresentada à Faculdade de Ciências
Agronômicas da Unesp – Campus de Botucatu,
para obtenção do título de Doutor em
Agronomia (Energia na Agricultura)

BOTUCATU - SP

Abril – 2012

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE CIÊNCIAS AGRONÔMICAS
CAMPUS DE BOTUCATU

**GEOESTATÍSTICA, SIMULAÇÃO ESTOCÁSTICA E
SENSORIAMENTO REMOTO NA ESTIMATIVA DE PRODUÇÃO DO
CAFÉ CONILON**

WAYLSON ZANCANELLA QUARTEZANI

Orientadora: Prof. Dr. Célia Regina Lopes Zimback

Tese apresentada à Faculdade de Ciências
Agronômicas da Unesp – Campus de Botucatu,
para obtenção do título de Doutor em
Agronomia (Energia na Agricultura)

BOTUCATU - SP

Abril – 2012

FICHA CATALOGRÁFICA ELABORADA PELA SEÇÃO TÉCNICA DE AQUISIÇÃO E TRATAMENTO DA INFORMAÇÃO - SERVIÇO TÉCNICO DE BIBLIOTECA E DOCUMENTAÇÃO - UNESP - FCA - LAGEADO - BOTUCATU (SP)

Q1g Quartezani, Waylson Zancanella, 1983-
 Geoestatística, simulação estocástica e sensoriamento remoto na estimativa de produção do café conilon / Waylson Zancanella Quartezani. - Botucatu : [s.n.], 2012
 ix, 82 f. : gráfs. color., tabs., maps. color., fots. color.

 Tese (Doutorado) - Universidade Estadual Paulista, Faculdade de Ciências Agrônômicas, Botucatu, 2012

 Orientador: Célia regina Lopes Zimback
 Inclui bibliografia

 1. Agricultura de precisão. 2. Análise estocástica. 3. Geologia - Métodos estatísticos. 4. Krigagem. 5. Sensoriamento remoto - Café - Cultivo. I. Zimback, Célia Regina Lopes. II. Universidade Estadual Paulista "Júlio de Mesquita Filho" (Campus de Botucatu). Faculdade de Ciências Agrônômicas. III. Título.

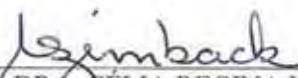
UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"
FACULDADE DE CIÊNCIAS AGRONÔMICAS
CAMPUS DE BOTUCATU
CERTIFICADO DE APROVAÇÃO

TÍTULO: "GEOESTATÍSTICA, SIMULAÇÃO ESTOCÁSTICA E SENSORIAMENTO
REMOTO NA ESTIMATIVA DE PRODUÇÃO DO CAFÉ CONILON"

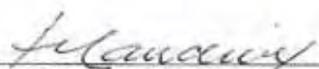
ALUNO: WAYLSON ZANCANELLA QUARTEZANI

ORIENTADOR: PROFA. DRA. CÉLIA REGINA LOPES ZIMBACK

Aprovado pela Comissão Examinadora



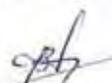
PROFA. DRA. CÉLIA REGINA LOPES ZIMBACK



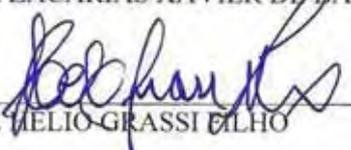
PROF. DR. PAULO MILTON BARBOSA LANDIM



PROF. DR. EDNALDO CARVALHO GUIMARÃES



PROF. DR. ZACARIAS XAVIER DE BARROS



PROF. DR. HELIO GRASSI FILHO

Data da Realização: 14 de maio de 2012

Num futuro virtual, será surreal viver a realidade.

Waylson Zancanella Quartezi

SUMÁRIO

	Páginas
SUMÁRIO.....	II
LISTA DE FIGURAS	IV
LISTA DE TABELAS	VI
LISTA DE EQUAÇÕES	VII
1 RESUMO	1
2 SUMMARY	3
3 INTRODUÇÃO.....	5
4 REVISÃO BIBLIOGRÁFICA	8
4.1 Sistema de Informações Geográficas (SIG).....	9
4.2 Sensoriamento remoto	10
4.2.1 Comportamento espectral e índice de vegetação	11
4.3 Geoestatística	12
4.3.1 Histórico e teoria das variáveis regionalizadas	12
4.3.2 Variograma.....	13
4.3.3 Krigagem.....	16
4.3.4 Simulação estocástica.....	18
4.3.4.1 Simulação e Cosimulação Sequencial Direta.....	19
4.4 Aplicações do geoprocessamento na cafeicultura	22
4.4.1 Variabilidade espacial x cafeicultura	22
4.4.2 Sensoriamento remoto na cafeicultura	24
5 MATERIAIS E MÉTODOS.....	26
5.1 Caracterização da área experimental	26
5.1.1 Localização e edafologia.....	26
5.1.2 Dados climáticos	27
5.2 Espécie cultivada	29
5.3 Malha amostral	29
5.4 Determinação da variável de planta.....	30
5.5 Aquisição da imagem de satélite	32

5.6 Programas computacionais	32
5.7 Processamento digital da imagem.....	32
5.7.1 Pré-processamento	33
5.7.2 Transformação.....	33
5.8 Análise dos dados	35
5.8.1 Análise descritiva	35
5.8.2 Análise geoestatística	36
5.8.3 Análise de simulação.....	36
5.8.3.1 Cokrigagem colocalizada	38
5.8.3.2 Modelo de correionalização local	39
5.8.3.3 Validação das simulações.....	40
5.8.3.4 Mapas simulados	40
6 RESULTADOS E DISCUSSÃO	42
6.1 Variável de planta usada como dado primário.....	42
6.1.1 Análise exploratória	42
6.1.2 Análise da continuidade espacial da variável CM	44
6.1.3 Estimção da variável CM	45
6.2 Imagens do IVs usados como dados Secundários	46
6.3 Simulação Sequencial Direta (DSS).....	51
6.3.1 Incertezas associadas às imagens simuladas pela DSS	52
6.4 Cosimulação Sequência Direta colocalizada com correlação global (CoDSS_CCG).....	53
6.4.1 Incerteza associada às imagens simuladas pela CoDSS_CCG	57
6.5 Cosimulação Sequência Direta colocalizada com correlação local (CoDSS_CCL)	60
6.5.1 Mapas de correlações locais.....	60
6.5.2 Incerteza associada às imagens simuladas pela CoDSS_CCL.....	62
6.6 Análise da incerteza dos métodos de simulação	65
6.7 Quantificação da incerteza.....	66
6.8 Considerações finais.....	73
7 CONCLUSÃO.....	75
8 REFERENCIAS BIBLIOGRÁFICAS	76

LISTA DE FIGURAS

	Páginas
Figura 1. Representação gráfica de um variograma típico e seus componentes.....	15
Figura 2. Representação visual do princípio de estimativa dos interpoladores para inferir valores, de uma variável distribuída no espaço, em locais não amostrados.....	17
Figura 3. Localização da lavoura comercial no município de São Mateus no Estado do Espírito Santo com a caracterização da área experimental para coleta dos dados.....	27
Figura 4. Precipitação pluviométrica ocorrida para o período de abril/2009 a março/2010, baseada na medição de pluviômetro instalado na área em estudo.....	28
Figura 5. Vista parcial de um dos talhões da área comercial de <i>Coffea canephora</i> utilizada em estudo, com destaque para as fileiras com número médio de 4 hastes (ramos plagiotrópicos) por planta e coloração amarelada de algumas ramos, indicando extração de nutrientes pela produção.....	29
Figura 6. Modelo Numérico de Elevação da área em estudo com a distribuição dos pontos amostrais na malha.....	30
Figura 7. Processos de obtenção da variável CM: (A) estágio de maturação dos frutos de café úmido na época da colheita; (B) colheita manual com derrça em peneira; (C) esquema de identificação das amostras colhidas; (D) Pesagem das amostras de café úmido em balança comercial.....	31
Figura 8. Histograma da variável de planta Café Maduro (CM).....	43
Figura 9. Variogramas da variável CM para as direções N-S (0°), NE-SW (45°), E-W (90°), NW-SE (-45°) e omnidirecional (0°; 0°), respectivamente.....	44
Figura 10. Mapa e histograma da krigagem para a variável primária CM.....	46
Figura 11. Mapas dos IVs usados como dados secundários.....	47
Figura 12. Variogramas dos IVs GNDVI e GNIR para as direções N-S (0°) e E-W (90°).....	48
Figura 13. Variogramas dos IVs IVN, NDVI, RNIR e VDn para as direções N-S (0°) e E-W (90°).....	49
Figura 14. Variogramas do IV VMn para as direções N-S (0°) e E-W (90°).....	50
Figura 15. Mapa, histograma e variogramas da simulação 1, de uma série de 50 simulações para a variável CM por DSS.....	51

Figura 16. Mapa de variância e histograma das incertezas associadas a variável CM por DSS.....	52
Figura 17. Mapa, histograma e variogramas das cosimulações CM_GNDVI e CM_GNIR.....	54
Figura 18. Mapa, histograma e variogramas das cosimulações CM_IVN e CM_NDVI.....	55
Figura 19. Mapa, histograma e variogramas das cosimulações CM_RNIR e CM_VDn.....	56
Figura 20. Mapa, histograma e variogramas da cosimulação CM_VMn.....	57
Figura 21. Mapas das variâncias das imagens simuladas da variável CM por CoDSS_CCG.....	58
Figura 22. Histograma das incertezas associadas aos mapas simulados por CoDSS_CCG.....	59
Figura 23. Mapas das correlações locais estimados por krigagem.....	61
Figura 24. Mapas de variância das imagens simuladas da variável CM por CoDSS_CCL.....	63
Figura 25. Histograma das incertezas associadas aos mapas simulados por CoDSS_CCL.....	64
Figura 26. Mapas de quantificação da incerteza associada a variável CM pela DSS e CoDSS_CCG com limite de corte baseado no valor médio do Perc ₉₅ , para cada IV, respectivamente.....	67
Figura 27. Mapas de quantificação da incerteza associada a variável CM pela CoDSS_CCL com limite de corte baseado no valor médio do Perc ₉₅ , para cada IV.....	68
Figura 28. Gráficos de correlação entre a variável CM e os IVs.....	71
Figura 29. Gráfico de correlação GNDVI_CM dividido em dois, utilizando o valor 14 kg da variável CM como limite de corte.....	72

LISTA DE TABELAS

	Páginas
Tabela 1. Análise estatística descritiva da variável de planta CM em estudo.....	42
Tabela 2. Estatísticas dos valores estimados por krigagem da variável CM.....	46
Tabela 3. Correlação entre os Índices de Vegetação (IVs).....	50
Tabela 4. Correlação global entre os IVs e a variável primária CM.....	53
Tabela 5. Valores do Coeficiente de assimetria dos mapas de variância para DSS e CODSS com correlação global e local.....	65
Tabela 6. Quantificação por área (ha e %) da incerteza associa a variável CM pela DSS e para cada imagem secundária (IV) nos 2 casos de Cosimulações testados.....	70

LISTA DE EQUAÇÕES

	Páginas
(1) Modelo do variograma proposto por Matheron.....	14
(2) Equação da krigagem ordinária.....	17
(3) Equação para condição de tendência não significativa pela krigagem.....	18
(4) Equação para condição de variância mínima pela krigagem.....	18
(5) Equação da média local estimada.....	20
(6) Equação da variância da estimação.....	20
(7) GNDVI - Índice de Vegetação da Diferença de Verde Normalizada.....	34
(8) GNIR - Razão entre o Verde e o Infravermelho.....	34
(9) IV _n - Banda Infravermelho Normalizada.....	34
(10) NDVI - Índice de Vegetação da Diferença Normalizada.....	34
(11) RNIR - Razão entre o vermelho e Infravermelho.....	34
(12) VD _n - Banda Verde Normalizada.....	35
(13) VM _n - Banda Vermelho Normalizada.....	35
(14) Estimador da krigagem simples Colocalizada.....	38

(15) Cokrigagem Colocalizada de acordo com a aproximação de Markov-Bayes.....	38
---	----

LISTA DE ABREVIATURAS

- C_s - Coeficiente de Assimetria.
- CM - Produção de café maduro (kg).
- CoDSS - Cosimulação Sequencial Direta.
- CoDSS_CCG - Cosimulação Sequencial Direta Colocalizada com Correlação Global.
- CoDSS_CCL - Cosimulação Sequencial Direta Colocalizada com Correlação Local.
- DSS - Simulação Sequencial Direta.
- GNDVI - Índice de Vegetação da Diferença de Verde Normalizada.
- GNIR - Razão entre o Verde e o Infravermelho.
- IV_n - Banda Infravermelho Normalizada.
- IVs - Índices de Vegetação.
- NDVI - Índice de Vegetação da Diferença Normalizada.
- RNIR - Razão entre o vermelho e Infravermelho.
- VD_n - Banda Verde Normalizada.
- VM_n - Banda Vermelho Normalizada.

1 RESUMO

A necessidade de técnicas e ferramentas que contribuem de forma simples, rápida e eficaz no monitoramento do sistema produtivo, como a avaliação do comportamento da variabilidade espacial das culturas agrícolas e o uso de sensores remotos, analisados em conjunto, para estimativa de atributos de culturas agrícolas, como o café, vêm se tornando um dos pilares na obtenção de uma agricultura precisa e sustentável. O objetivo do trabalho foi estimar e simular a produção de café maduro (CM) em kg por meio de técnicas Geoestatísticas e de Sensoriamento Remoto (SR), utilizando imagens de satélite, para a predição da produção e determinação das áreas de incerteza. O estudo foi realizado em uma área comercial de café conilon, *Coffea canephora* Pierre, Var. conilon, no Município de São Mateus - (ES), onde foi amostrada em campo a produção de café maduro em uma malha irregular de 18,5 ha, totalizando 87 pontos. Ajustado o variograma, estimou-se a variável primária (CM) pela krigagem e como variáveis secundárias foram gerados Índices de Vegetação (IVs) da transformação das imagens de satélite. De posse das imagens primária e secundária, aplicou a Simulação Sequencial Direta (DSS) para o caso de simulação sem o uso de imagem secundária e Cosimulação Sequencial Direta colocalizada (CoDSS) para simular a variável CM, utilizando os IVs como imagens secundárias. Na CoDSS foram testadas correlações globais (CoDSS_CCG) e locais (CoDSS_CCL) entre a variável CM e os IVs. Em cada um dos 3 métodos de simulação e para cada IV, na CoDSS, foram realizadas 50

simulações. Atendendo aos pressupostos exigidos pelos métodos de simulações, foram analisados as estatísticas, histograma e variografia das simulações. A variável CM ajustou-se ao variograma esférico com alcance de 150 m, correspondendo às dimensões médias dos talhões de café na área. Este alcance foi encontrado também para os IVs, o que comprova a alta correlação espacial com a variável CM. O mesmo ocorreu na análise de correlação entre os IVs, impossibilitando a aplicação de ferramentas multivariadas, levando a análise individual de cada IV no seu uso como imagem secundária. Na quantificação da incerteza, os mapas de variância das simulações mostraram que a DSS apresentou maior área de incerteza que os métodos de CoDSS, comprovando a maior eficiência das simulações utilizando os IVs como imagens secundárias na identificação de áreas de incerteza para melhor determinação da produção da variável CM. Não foram encontradas diferenças significativas entre os IVs nos métodos de CoDSS. Apesar de pouco significativo, a CoDSS_CCG mostrou maior eficiência que a CoDSS_CCL, onde nesta última, a baixa resolução espacial (20 m) das imagens de satélite afetou de forma negativa os resultados desse método de CoDSS.

Palavras-chave: Agricultura de precisão, índices de vegetação, cokrigagem colocalizada.

GEOSTATISTICS, STOCHASTIC SIMULATION AND REMOTE SENSING ON ESTIMATE OF PRODUCTION OF COFFEE CONILON. Botucatu, 2012. 82p. Tese (Doutorado em Agronomia / Energia na Agricultura) – Faculdade de Ciências Agronômicas, Universidade Estadual Paulista.

Author: Waylson Zancanella Quartezi

Adviser: Célia Regina Lopez Zimback

2 SUMMARY

The need for techniques and tools that contribute in a simple, quick and efficient way to monitor the productive system, as the performance assessment of the spatial variability of crop and the use of remote sensors, analyzed together, to estimate the attributes of crop, as coffee, have become a mainstay in obtaining an accurate and sustainable agriculture. The aim of the study was to estimate and simulate the production of mature coffee (CM) in kg by using the techniques of Geostatistical and Remote Sensing (SR), using satellite images, to the production prediction and determining areas of uncertainty. The study were done in a commercial area of conilon coffee, *Coffea canephora* Pierre, Var. conilon, at the city of São Mateus - (ES), where the production of mature coffee was sampled in field in an irregular mesh of 18,5 ha, totaling 87 points. Adjusted the variogram, was estimated the primary variable (CM) by kriging and as secondary variables were generated Vegetation Index (IVs) of processing of the satellite images. Having the primary and secondary images, was applied the Direct Sequential Simulation (DSS) for the case of simulation without the use of the secondary image and Direct Sequential Co-simulation co-located (CoDSS) to simulate the variable CM, using the IVs as secondary images. In the CoDSS were tested global correlations (CoDSS_CCG) and locals (CoDSS_CCL) between the CM variable and the IVs. In each one of three simulation methods and for each IV, on CoDSS, were done 50 simulations. Considering the assumptions required by the simulation methods, were analyzed statistics, histograms and variography of the simulations. The variable CM was adjusted to the spherical

variogram with a range of 150 m, corresponding to the average size of the coffee fields in the area. This range was also found for the IVs, what confirms the high spatial correlation with the variable CM. The same occurred in the correlation analysis between the IVs, making impossible the application of multivariate tools, leading to individual analysis of each IV in its use as a secondary image. In the quantification of uncertainty, the variance maps of the simulations showed that the DSS had the largest area of uncertainty that the methods of CoDSS, proving the higher efficiency of the simulations using the IVs as secondary images in identifying areas of uncertainty for better measurement of the production of variable CM. Were not find significant differences between the IVs in the CoDSS methods. Although negligible, the CoDSS_CCG showed higher efficiency than the CoDSS_CCL, where in the last one, the low spatial resolution (20 m) satellite images has affected negatively the results of this CoDSS method.

Keywords: Precision farming, vegetation index, collocated cokriging.

3 INTRODUÇÃO

A falta de conhecimento na utilização e interação entre elementos considerados essenciais para o pleno desenvolvimento das áreas cultivadas dificulta a obtenção de um sistema de produção com caráter mais produtivo, lucrativo e com menor agressão e impacto ao meio ambiente.

Uma forma de minimizar essa falta de conhecimento seria entendendo melhor e modelando a variabilidade espacial dos elementos e parâmetros que estão diretamente relacionados com a produção das culturas. Na agricultura moderna, o gerenciamento em função da variabilidade é o primeiro passo tomado para a implantação de um sistema de produção, conhecida como Agricultura de Precisão (AP), que tem como objetivo uma maior eficiência, com a utilização de um gerenciamento localizado de informações na área de produção, para definição de zonas de manejo específicas, por meio da confecção de mapas.

Portanto, existe uma necessidade cada vez maior por técnicas e ferramentas que contribuem de forma simples, rápida e eficaz para o monitoramento de todo o sistema produtivo. Dentre elas, a avaliação do comportamento da variabilidade espacial dos atributos e parâmetros das culturas agrícolas e o uso de sensores remotos, principalmente quando analisados em conjunto, objetivando a estimação e simulação de tais atributos e

parâmetros de culturas agrícolas, como o café. O que vêm se tornando um dos pilares na obtenção de uma agricultura precisa e sustentável.

A aplicação dessas novas tecnologias no campo pode ser obtida com o uso de ferramentas embasadas no geoprocessamento, no caso, com a utilização de técnicas como a geoestatística e o sensoriamento remoto, que auxiliadas por um SIG (Sistema de Informações Geográficas) e analisadas em conjunto, podem promover a otimização da produção, com maior aproveitamento de recursos obtidos com a correta quantidade aplicada de fertilizantes e defensivos; maximização dos lucros, com a redução de custos com coletas de amostras de solos e plantas, análises laboratoriais e insumos; e proteção ao meio ambiente com a diminuição do uso abusivo de insumos e fertilizantes.

A maioria dos trabalhos disponíveis envolvendo mapeamento da variabilidade espacial de parâmetros de plantas tem sido desenvolvida para culturas anuais. No caso de culturas perenes como, por exemplo, o café, os sistemas de mapeamento de produtividade estão menos desenvolvidos, devido à menor utilização da colheita mecanizada. Por outro lado, é um produto de elevado valor comercial, pois emprega altas doses de fertilizantes e defensivos, aumentando assim, a possibilidade de viabilização econômica com o emprego das ferramentas embasadas no geoprocessamento e na AP.

O mapeamento da variabilidade espacial de parâmetros de planta, como a produtividade, podem ainda contribuir muito para um melhor planejamento na implantação de culturas em novas áreas. No caso da cultura do café conilon, para a Região Norte do Estado do Espírito Santo, pode propiciar um manejo mais adequado das áreas de cultivo, tornando-as mais produtivas a um custo por saca beneficiada, ainda menor, como também o estabelecimento de novas lavouras comerciais com potencial produtivo e menor custo.

Então o trabalho teve como objetivo geral estimar e simular a variável produção de café conilon (*Coffea canephora* Pierre ex Froehner) no município de São Mateus – ES, para a sua melhor predição com a identificação de áreas de incerteza, utilizando técnicas de geoestatísticas e sensoriamento remoto.

Os objetivos específicos foram:

- amostrar e avaliar a variável de planta: produção de café maduro (CM);

- estimar os valores da variável de planta a ser estudada, em locais não amostrados na área, utilizando técnicas de interpolação por krigagem para a confecção de mapa temático;
- simular a variável CM utilizando a técnica de Simulação Sequencial Direta (DSS);
- determinar Índices de vegetação (IVs) com uso de imagens de satélite para a cultura do café conilon;
- analisar a correlação entre os IVs para identificação de multicolinearidades e definição da sua utilização de forma multivariada ou individualmente;
- correlacionar os IVs com a variável CM na identificação dos melhores índices para utilização como imagens secundárias;
- simular a variável CM utilizando os IVs como imagens secundárias por meio da Cosimulação Sequencial Direta colocalizada (CoDSS), testando correlações globais (CoDSS_CCG) e locais (CoDSS_CCL);
- gerar mapas de variância das simulações realizadas por DSS e CoDSS para identificação de áreas de incerteza associadas a variável CM;
- quantificar as incertezas para comparação dos métodos de simulação.

4 REVISÃO BIBLIOGRÁFICA

Para que se alcance o máximo de rendimento, de acordo com as potencialidades do solo e com o mínimo de poluição e degradação, é necessário o acompanhamento e gerenciamento de um volume muito grande de informações que variam no espaço e no tempo (ROCHA; LAMPARELLI, 1998). Podem-se considerar como essencial para esse sistema, o geoprocessamento.

O geoprocessamento pode ser definido como um conjunto de tecnologias voltadas à coleta e tratamento de informações espaciais para um objetivo específico. Câmara e Medeiros (1998) enfatizaram que o termo geoprocessamento é utilizado para denotar o conjunto de técnicas matemáticas e computacionais para o tratamento de informações geográficas. Sua influência é crescente nas diversas áreas como: cartografia, análise de recursos naturais, transportes, comunicações, planejamento urbano e regional e energia.

As atividades que envolvem o geoprocessamento são executadas por sistemas específicos, como: Sistemas de Informações Geográficas (SIG), Sensoriamento Remoto e Geoestatística.

4.1 Sistema de Informações Geográficas (SIG)

Formaggio et al. (1992) concluíram que os sistemas de informação geográfica constituem uma das mais modernas e promissoras tendências de armazenamento e manipulação de informações temáticas sobre recursos naturais terrestres, em complemento, e até em substituição, aos mapas impressos em papel. Em física do solo, o SIG pode contribuir para sintetizar as informações de campo e proporcionar uma eficiente avaliação das propriedades dos solos, detectando áreas com problemas e contribuindo para a aplicação na Agricultura de Precisão (AP).

O uso de mapas, gráficos e outros recursos que sintetizam um conjunto de informações são preferidos quando se dispõe de um grande conjunto de dados, porque proporciona uma interpretação rápida e direta da variável (MANTOVANI et al., 1998). Segundo Burrough, (1986) citado por Rocha e Lamparelli (1998), o SIG pode ser considerado um poderoso elenco de ferramentas para colecionar, armazenar, recuperar, transformar e exibir dados espaciais referenciados ao mundo real. O SIG requer o uso do meio digital, portanto, o uso intensivo da informática é imprescindível. Ele deve ter uma base de dados integrada que precisa estar georreferenciada e com controle de erro. Num SIG, dados da variabilidade da produtividade podem ser analisados conjuntamente com outros dados, como os de solos ou modelos digitais de elevação, para modelar cenários futuros e avaliar a efetividade do manejo utilizado (PECCOL et al., 1994, citados por ROCHA; LAMPARELLI, 1998).

O SIG normalmente integra diversos outros sistemas como o processamento digital de imagens, a análise estatística, a análise geográfica e a digitalização, tendo como ponto central um banco de dados. Desta forma, segundo Rocha e Lamparelli (1998), um SIG pode ser dividido em sistemas de:

- 1) entrada de dados: processamento digital de imagens (PDI), digitalização de mapas, sistema de posicionamento global (GPS), dados tabulares (planilhas eletrônicas) e dados estatísticos;

- 2) armazenamento de dados: banco de dados espacial (mapas digitais) e banco de dados de atributos (alfanuméricos);

3) análise de dados: análise geográfica, análise estatística e gerenciamento do banco de dados (SGBD); e

4) saída de dados: exibição cartográfica com saída de mapas para a tela, impressora, plotter e arquivos digitais.

A interação com o proprietário da área analisada é essencial, pois muitas vezes só ele conhece o histórico da área e, neste sentido, algumas vezes a variabilidade espacial da produtividade encontrada no campo pode ser resultado de outros fatores que não os tradicionais (como fertilidade), mas sim de diferenças de manejo. Vê-se então que o SIG pode ser considerado uma plataforma ideal para o tratamento de dados, pois com a utilização de suas ferramentas será possível uma ampla análise dos mesmos. (ROCHA; LAMPARELLI, 1998).

4.2 Sensoriamento remoto

Segundo Campos (2005) sensoriamento remoto é o conjunto de técnicas destinado à obtenção de informação sobre objetos, sem que haja contato físico com eles. A aquisição de dados em sistemas de sensoriamento remoto registra, em selecionadas faixas de comprimento de onda, a quantidade de energia refletida ou emitida por objetos na superfície terrestre. Um ingrediente básico e essencial na análise e interpretação de dados de sensores remotos está voltado para as características espectrais dos vários tipos de vegetação, solo, água, e outras características da superfície terrestre.

Novo (2008) definiu o sensoriamento remoto como sendo a utilização conjunta de sensores, equipamentos para processamento de dados, equipamentos de transmissão de dados colocados a bordo de espaçonaves, ou outras plataformas, com o objetivo de estudar eventos, fenômenos e processos que ocorrem na superfície do planeta Terra a partir do registro e da análise das interações entre a radiação eletromagnética e as substâncias que o compõem em suas mais diversas manifestações.

Os níveis de aquisição de dados de sensoriamento remoto dependem do veículo de suporte para a operação de um sistema sensor. Este veículo ou sistema de suporte recebe o nome genérico de plataforma e as mais comuns são os satélites e aeronaves

(NOVO, 2008). Jensen (1949) designa o termo plataforma orbital para os satélites e plataforma suborbital para aeronaves, tendo geralmente os sensores remotos orbitais, ou seja, imagens de satélite, fornecendo dados de alta qualidade e relativamente baratos quando analisados por km².

A imagem de satélite é uma ferramenta que pode ser utilizada para gerar informações que são obtidas por meio do comportamento espectral da cultura. As diferenças espectrais são registradas na imagem na forma de variações tonais de cores ou de intensidade. Portanto, os sensores remotos buscam detectar e mostrar as diferenças em tonalidades ou cor entre um objeto e o ambiente em que se encontram (VALÉRIO FILHO, 1996).

4.2.1 Comportamento espectral e índice de vegetação

Dentre os principais trabalhos com sensoriamento remoto, os objetivos são voltados para classificação e estimativa de áreas, estimativa de produtividade e identificação de variedades, que são possíveis graças aos diferentes comportamentos espectrais dos objetos estudados. O comportamento espectral do dossel vegetal manifesta-se de forma semelhante a uma folha verde sadia, distintas em três regiões espectrais, que são as regiões do visível, do infravermelho próximo e do infravermelho médio (PONZONI, 2001).

Segundo Hoffer (1978) nos comprimentos de onda do visível, a pigmentação, em especial a clorofila, domina a resposta espectral de plantas. A refletância nas folhas verdes apresenta-se muito baixa, nos comprimentos de onda do azul e do vermelho. Uma falta relativa de absorção nos comprimentos de onda entre as duas faixas de absorção de clorofila permite um pico de refletância para acontecer em torno de 0,54 µm, que é a região de comprimento de onda verde. Quando uma planta está sob tensão e a produção de clorofila é diminuída, terão uma refletância mais alta, particularmente na porção vermelha do espectro, parecendo amareladas. Na faixa do infravermelho próximo do espectro, a vegetação verde saudável é caracterizada por uma alta refletância, alta transmitância e muito baixa absorptância, em comparação com os comprimentos de onda visíveis. É importante notar que, em comparação com a refletância de uma única folha as camadas de múltiplas folhas podem causar uma refletância muito mais alta (até 85%) na porção do infravermelho próximo do

espectro. Isto é devido à refletância aditiva, que é a energia transmitida pela primeira camada de folhas (no lugar mais alto) e refletida de uma segunda camada que está parcialmente transmitida por trás da primeira camada. A modelagem de camadas de múltiplas folhas mostra aumentos significantes na refletância do infravermelho próximo, quando mais camadas de folha são adicionadas.

A resposta espectral do dossel de uma cultura pode ser influenciada por diversos fatores como: umidade, vigor vegetativo, cobertura vegetal do substrato, tipo de solo, topografia, espaçamento da cultura, variedade, idade da planta e culturas intercalares, entre outros (VIEIRA et al., 2003). Na porção visível do espectro, existe uma diminuição distinta na refletância para solo úmido, em comparação com o solo seco. A região climática e as condições de drenagem devem ser levadas em conta, quando se considera a relação entre refletância espectral e o conteúdo de matéria orgânica dos solos. Um aumento no óxido de ferro pode causar uma diminuição significativa na refletância, pelo menos nos comprimentos de onda visível (HOFFER, 1978).

As aplicações de sensoriamento remoto no estudo de culturas agrícolas têm feito uso extensivo dos índices de vegetação, para avaliar a refletância do dossel de culturas. Pois estes são combinações entre bandas espectrais, que servem para realçar as feições de vegetação e também minimizar efeitos do solo, angulares e atmosféricos (EPIPHANIO et al., 1996). Desse modo, a transformação de dados espectrais em índices de vegetação, que tem por função maximizar a variável em estudo e minimizar diferentes fatores de variação (arquitetura do dossel, influência dos solos, estágio fenológico da vegetação, entre outros), busca uma melhor compreensão das variações observadas nas imagens, assim como permite que sejam feitas verificações das modificações apresentadas na cobertura vegetal.

4.3 Geoestatística

4.3.1 Histórico e teoria das variáveis regionalizadas

A Geoestatística teve as suas primeiras aplicações em mineração (BLAIS; CARLIER, 1968). Segundo Vieira (2000a), a geoestatística surgiu quando Krige em

1951, trabalhando na África do Sul com dados de concentração de ouro, concluiu que não conseguia encontrar sentido nas variâncias, se não levasse em conta a distância entre as amostras.

Existem vários estudos em ciência do solo (HAJRASULIHA et al., 1980; BURGESS e WEBSTER, 1980a e 1980b), além ainda, de alguns livros tratando do assunto, dentre os quais se destacam David (1977) e Journel e Huijbregts (1978). Isso se tornou possível após Matheron (1963, 1971), baseado nas observações de Krige, desenvolver uma teoria, a qual ele nomeou de Teoria das Variáveis Regionalizadas, que contém os fundamentos da geoestatística.

Matheron (1963) definiu Variável Regionalizada como uma função espacial numérica, que varia de um local para outro, com uma continuidade aparente e cuja variação não pode ser representada por uma função matemática simples, mas sim por um variograma. Segundo essa teoria, a diferença nos valores de uma dada variável tomada em dois pontos no campo depende da distância entre eles. Com isso, a diferença entre os valores do atributo tomados em dois pontos mais próximos no espaço deve ser menor do que a diferença entre valores tomados em dois pontos mais distantes. Logo, cada valor carrega consigo uma forte interferência dos valores de sua vizinhança, ilustrando uma continuidade espacial (ISAAKS; SRIVASTAVA, 1989).

Segundo Vieira (1996) quando se tem um conjunto de valores medidos ($Z(x_i)$) em uma área S , cada amostra apresenta uma coordenada de localização (x, y) que pode ser considerada como a realização de certa variável aleatória $Z(x_i)$ e o conjunto delas será uma função aleatória. Quando se tem uma única amostragem por ponto e deseja-se estimar valores para locais não amostrados, é necessário introduzir a restrição de que a variável regionalizada deve ser necessariamente estacionária.

4.3.2 Variograma

A estimativa da dependência espacial entre amostras vizinhas no espaço pode ser realizada através da autocorrelação que é de grande utilidade quando se está

fazendo amostragem em uma direção. Porém, quando a amostragem envolve duas direções (x, y), o instrumento mais indicado na estimativa da dependência espacial entre amostras é o variograma (SILVA, 1988), ou ainda, quando a interpolação entre locais medidos for necessária para a construção de mapas de isolinhas (VIEIRA et al., 1983).

O variograma é o gráfico que expressa a variação do atributo com a distância entre pontos no campo de amostragem. A variância total de um determinado atributo é desmembrada em diferentes distâncias amostradas e, com isso, objetiva-se encontrar a estrutura da variância. Se a variância aumenta com o aumento da distância, isso quer dizer que a variância e a distância covariam, indicando que são variáveis dependentes (SILVA, 1988).

Ele é definido a partir da variância espacial das medidas feitas em amostras espaçadas no campo de determinada distância h, ou seja, “lag” (WEBSTER, 1985), sendo a soma dos quadrados da diferença entre valores amostrados, separados por uma distância (h), divididos por duas vezes o número de pares possíveis e é estimado pela seguinte equação:

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad (1)$$

em que: N(h) é o número de pares de valores medidos Z(x_i), Z(x_i+h) separados por um vetor h; e Z(x_i) é a variável aleatória em estudo na i-ésima posição.

O gráfico da variância espacial *versus* a distância h (Figura 1) representa o variograma, que permite obter a estimativa do valor de variância para as diferentes combinações de pares de pontos e assim analisar o grau de dependência espacial da variável estudada e definir os parâmetros necessários para a estimativa de suas características em locais não amostrados (SOUZA, 1999).

Segundo Vieira (1998), em um variograma são estimados os parâmetros efeito pepita (*nugget effect*), patamar (*sill*) e alcance (*range*), representados respectivamente pelos símbolos C₀, C₀+C e **a**, como pode ser visto na Figura 1.

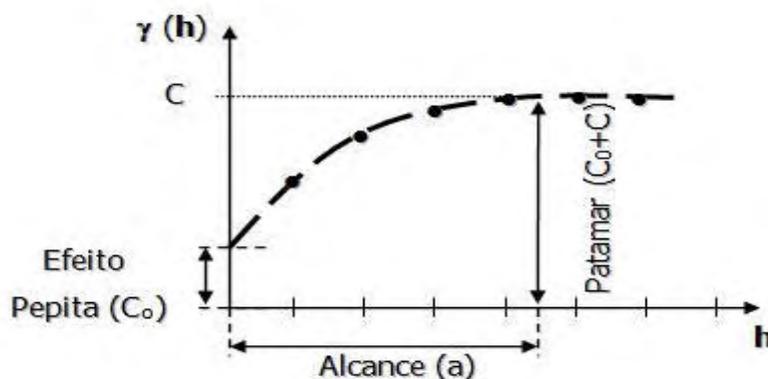


Figura 1. Representação gráfica de um variograma típico e seus componentes.

Espera-se que: as diferenças $[Z(x_i) - Z(x_i+h)]$ decresçam assim que a distância (h) que os separa, decresça; as medições localizadas próximas sejam mais parecidas entre si do que aquelas separadas por grandes distâncias; e que $\gamma(h)$ aumente com a distância h . Por definição, $\gamma(0) = 0$, como pode ser visto pela equação 1, quando $h=0$. Entretanto, na prática, o valor de $\gamma(h)$ próximo à origem, ou seja, para h próximo de 0 (zero), tende a um valor positivo, chamado efeito pepita (C_0), que dita a descontinuidade do variograma. Quando h aumenta, frequentemente aumenta até uma distância a , chamada de alcance (a), a partir da qual a variância espacial neste ponto é chamada de patamar (C_0+C), cujo valor é aproximadamente igual à variância dos dados, se ela existe, e é obtida pela soma do efeito pepita e a variância estrutural (C) (VIEIRA, 2000a).

O valor de C_0 revela a descontinuidade do variograma para distâncias menores do que a menor distância entre as amostras. Parte dessa descontinuidade pode ser também devido a erros de medição, mas é impossível quantificar qual contribui mais, se os erros de medição ou variabilidade a uma escala menor do que aquela amostrada (VIEIRA, 2000a).

Souza (1992) afirmou que amostras separadas por distâncias menores que o alcance (a) são espacialmente dependentes, e que o mesmo é também utilizado para definir o raio de ação (“range”) máximo de interpolação por krigagem, onde os pesos utilizados na ponderação podem afetar os valores estimados. Segundo Silva (1988), o raio de ação é um dos parâmetros principais no estudo da variabilidade espacial, onde amostras

separadas por distâncias menores que o alcance (a) são correlacionadas umas às outras, o que permite que se faça interpolações para espaçamentos menores do que os amostrados.

Silva (1988) descreve ainda que o patamar é atingido quando a variância dos dados se torna constante com a distância entre as amostras. O patamar é um parâmetro importante, pois permite a determinação da distância limite (alcance) entre dependência e independência entre amostras. Dependendo do comportamento do variograma para grandes valores de h , o modelo pode ser classificado em duas categorias: modelos com patamar (Esférico, Exponencial e Gaussiano) e modelos sem patamar (modelos com capacidade infinita de dispersão, não tem variância finita e a covariância não pode ser definida).

4.3.3 Krigagem

A krigagem é o método de interpolação em geoestatística, sendo utilizada para obtenção de mapas espaciais de parâmetros de solo e plantas. Na maioria das vezes, o interesse da análise geoestatística não se limita à obtenção de um modelo de dependência espacial, desejando também predizer valores em pontos não amostrados. O interesse pode ser em um ou mais pontos específicos da área ou obter uma malha de pontos interpolados que permitam visualizar o comportamento da variável na região através de um mapa de isolinhas ou de superfície (SILVA JUNIOR, 2001).

Conhecido o variograma da variável e havendo dependência espacial entre as amostras, podem-se interpolar valores em qualquer posição no campo de estudo, sem tendência e com variância mínima (VIEIRA, 2000a). Para obter esse maior detalhamento da área em estudo é necessária aplicação da krigagem (SILVA JUNIOR, 2001).

O nome Krigagem foi dado por Matheron (1963) em homenagem ao sul-africano Krige (VIEIRA, 2000a). Segundo Salviano (1996), a krigagem é uma técnica usada na geoestatística com o objetivo de estimar valores de variáveis para locais onde as mesmas não foram medidas a partir de valores adjacentes interdependentes (Figura 2). O valor estimado da variável é dado pela equação:

$$\hat{Z}(x_0) = \sum_{i=1}^N \lambda_i Z(x_i) \quad (2)$$

em que: $\hat{Z}(x_0)$ é o valor estimado para local x_0 não amostrado; $Z(x_i)$ é o valor obtido por amostragem no campo; e λ_i é o peso associado ao valor medido na posição x_i .

De acordo com Ribeiro Júnior (1995) e Camargo (1997) o processo de krigagem se diferencia dos outros métodos de interpolação pela forma de atribuição dos pesos, que são variáveis de acordo com a variabilidade espacial expressa pelo variograma.

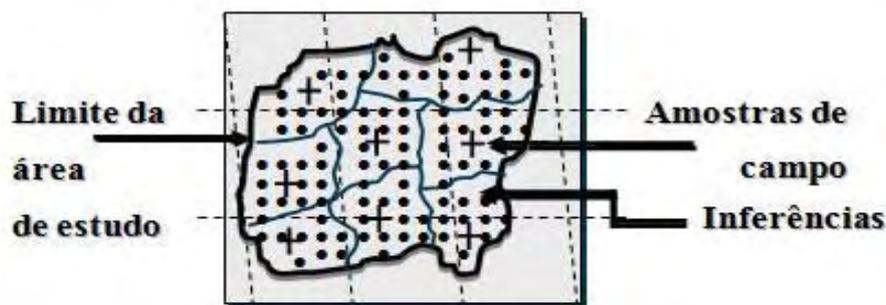


Figura 2. Representação visual do princípio de estimativa dos interpoladores para inferir valores, de uma variável distribuída no espaço, em locais não amostrados.

Fonte: Adaptado do INPE - Divisão de Processamento de Imagens (2000).

Esse estimador nada mais é que uma média móvel ponderada. O que torna a krigagem um interpolador ótimo, então, é a maneira como os pesos são distribuídos (VIEIRA, 2000a). Pontos próximos da posição a ser interpolada levam maiores pesos que os mais distantes, e ainda, as distâncias consideradas não são somente entre o ponto a ser predito e os vizinhos, mas também entre os vizinhos (SILVA JÚNIOR, 2001). Com isso podemos enfatizar que, para uma mesma distância, dados agrupados, terão menores pesos, quando comparados individualmente com pontos isolados, pois estes dados trazem informações quase redundantes de uma mesma região.

Segundo Vieira (1998), para que o estimador seja ótimo, o mesmo não pode ser tendencioso (Equação 3) e deve ter variância mínima (Equação 4). Essas duas condições devem ser rigorosamente satisfeitas e, para tanto, são usadas como ponto de partida

para a dedução das equações. A condição de não tendência significa que, em média, a diferença entre valores estimados e medidos para o mesmo ponto deve ser nula. A condição de variância mínima significa que, embora possam existir diferenças ponto por ponto entre o valor estimado e o medido, essas diferenças devem ser mínimas (VIEIRA, 2000a).

$$E \{Z^* (x_0) - Z(x_0)\} = 0 \quad (3)$$

$$\text{VAR} \{Z^* (x_0) - Z(x_0)\} = E \{[Z^* (x_0) - Z(x_0)]^2\} = \text{mínima} \quad (4)$$

Com a análise de mapas de contorno ou de superfície, gerados por meio da krigagem, pode-se tomar decisões importantes, por exemplo, em relação ao aumento da eficiência na utilização de fertilizantes, com redução de custo e aumento de produtividade (MULLA et al., 1992).

Os métodos de interpolação como a krigagem, que são modelos de estimação cujo objetivo é a inferência espacial das características médias de uma dada variável, consegue expressar os valores extremos locais de um dado ponto, mas não o comportamento simultâneo do conjunto de pontos. Este só é possível com várias realizações da distribuição conjunta no espaço dos valores da variável, que pode ser feito por meio de simulações.

4.3.4 Simulação estocástica

Os modelos de simulação estocástica têm como objetivo a elaboração de imagens “virtuais” da realidade que refletem as características do recurso natural, a variabilidade do conjunto de amostras, a lei de distribuição da variável em estudo e a continuidade espacial, tal qual é revelada pelos variogramas ou covariâncias, condições estas que não são abrangidas pelos modelos de estimação. Estes modelos fornecem um conjunto de imagens equiprováveis com a mesma variabilidade espacial dos dados experimentais, de modo que em todas as imagens sejam reproduzidas as mesmas estatísticas de variabilidade espacial (histograma e variograma ou covariância espacial), quantificados pelas amostras (SOARES, 2006).

Com este método de simulação não se pretende obter a imagem mais provável das características de um dado recurso, mas sim, um conjunto de imagens equiprováveis com a mesma variabilidade espacial dos valores experimentais. A incerteza espacial é obtida pela variabilidade do conjunto de imagens equiprováveis representativas do caso de estudo ou do fenômeno espacial. Este conjunto de imagens permite visualizar o comportamento extremo das características internas ou morfológicas de um dado recurso natural e simultaneamente, quantificar a incerteza da localização espacial dessas características (SANTOS, 2003).

A distribuição de probabilidade da estimativa local é realizada no âmbito da indicatriz ou do formalismo multiGaussiano. Mas vale ressaltar que as principais desvantagens de ambos os métodos são, direta ou indiretamente relacionados com a necessidade de transformar a variável original (SOARES, 2001). Para solucionar este problema, Soares (2001) propôs a utilização da Simulação e Cosimulação Sequencial Direta (CoDSS), onde este algoritmo de simulação difere da Simulação Sequencial Gaussiana tradicional por não requerer uma transformação prévia das variáveis originais para uma distribuição do tipo gaussiano.

4.3.4.1 Simulação e Cosimulação Sequencial Direta

Simulação Sequencial Direta (DSS) significa simular sem qualquer transformação da variável original e tem sido amplamente utilizada para a caracterização espacial de variáveis categóricas (SOARES, 1998).

Journel (1994) introduziu o primeiro passo para a simulação de uma variável contínua sem qualquer transformação prévia: ele demonstrou que a simulação direta de uma variável contínua, conseguiu reproduzir o modelo de covariância, porém ele não conseguiu reproduzir o histograma da variável contínua. Segundo Soares (2006), isso ocorreu devido às leis de distribuição não poderem ser totalmente caracterizadas somente pelas médias e variâncias locais das variáveis originais. Esta foi a razão pela qual este princípio só foi

transformado num modelo, precisamente quando a reprodução do histograma de $Z(x)$ foi assegurado por Soares (2001).

A ideia da Simulação Sequencial Direta (DSS) nasceu do seguinte postulado: se as leis de distribuições locais de $Z(x)$ são centradas no estimador de krigagem simples com a variância condicional local igual à variância de krigagem $\sigma_{ks}^2(x_0)$, então as covariâncias espaciais ou variogramas são necessariamente reproduzidos nos mapas finais simulados (JOURNEL, 1994). Bourgault (1997) e Caers (1999) deram uma demonstração prática dessa afirmação com vários tipos de distribuições. O problema é que este princípio garante a reprodução dos variogramas, mas não a do histograma da variável original (SOARES, 2006).

Soares (2001) postulou que o modelo de Simulação Sequencial Direta reside na utilização das médias e variâncias locais, não para definir as leis de distribuição locais como na Simulação Sequencial Gaussiana, mas para reamostrar a lei de distribuição global. Para tanto, são escolhidos intervalos de $Z(x)$ da lei de distribuição global $F_z(z)$ para se construir uma nova função $F'_z(z)$ sendo os valores $z^s(x_0)$ simulados a partir desta. Os intervalos na nova função $F'_z(z)$ são centrados na média local estimada por krigagem simples $[z(x_0)]^*$ e tem uma amplitude proporcional à variância condicional local estimada pela variância de estimação da krigagem simples $\sigma_{ks}^2(x_0)$. Um modo de definir estes intervalos consiste na seleção de um subconjunto de n valores contínuos $z(x_i)$ do histograma experimental global cuja média e variância, dos valores selecionados, seja igual ao estimador (krigagem simples) da média local $[z(x_0)]^*$ e à variância de estimação $\sigma_{ks}^2(x_0)$, respectivamente:

$$\frac{1}{n} \sum_{i=1}^n z(x_i) = [z(x_0)]^* \quad (5)$$

e

$$\frac{1}{n} \sum_{i=1}^n [z(x_i) - [z(x_0)]^*]^2 = \sigma_{ks}^2(x_0) \quad (6)$$

O valor simulado $z(x_i)$ seria assim gerado a partir de $F'_z(z)$ dos n valores selecionados.

Quando duas ou mais variáveis são espacialmente dependentes, a sua simulação deve reproduzir essa correlação além das distribuições e variogramas individuais. Com isso, os valores das variáveis devem ser gerados a partir de uma simulação conjunta ou Cosimulação. Existem basicamente duas abordagens para a Cosimulação de duas ou mais variáveis: a simulação simultânea a partir de uma multidistribuição (VERLY, 1993) ou por meio da aplicação da regra de Bayes em que a simulação de cada variável processa-se numa sequencia de simulações de distribuição condicionais (GOMEZ-HERNANDEZ; JOURNAL, 1993; GOOVAERTS, 1997). Esta última abordagem é a mais usual porque além de exigir menos assunções teóricas, a sua implementação é mais simples e o seu formato permite um melhor controle dos passos da Cosimulação e, conseqüentemente, dos resultados. A ideia não é mais do que a extensão do princípio da simulação sequencial, mas aplicado à totalidade dos campos aleatórios: vamos admitir N_u variáveis $Z_1(x), \dots, Z_{N_u}(x)$ que se pretendem cosimular. A simulação da distribuição conjunta processa-se de acordo com a relação: $F(Z_1, Z_2, \dots, Z_{N_u}) = F(Z_1)F(Z_2/Z_1) \dots F(Z_{N_u}/Z_1, \dots, Z_{N_u-1})$. Particularizando para o caso de $N_u = 2$ e considerando como variável “principal” $Z_1(x)$, como a primeira a ser simulada individualmente, que é normalmente a mais importante no processo de simulação ou a que tem uma maior continuidade espacial (ALMEIDA; JOURNAL, 1994), esta é simulada em primeiro lugar por um dos métodos de simulação sequencial. Seguidamente a variável $Z_2(x)$ é simulada, condicionada aos valores previamente simulados de $Z_1(x)$. Portanto, na localização espacial x_0 os valores de $Z_2(0)$ são gerados a partir da lei de distribuição condicional: $F_z(Z_2(x_0)/Z_2(x_\alpha) = z_2(x_\alpha), Z_1(x_i) = z_1^s(x_i), i = 1, N)$, em que $z_1^s(x_i)$ são os valores previamente simulados de $Z_1(x)$ e $z_2(x_\alpha)$ são os valores experimentais e os valores eventualmente já simulados de $Z_2(x)$ em torno de x_0 .

O processo de Cosimulação pode ser implementado com a simulação sequencial Gaussiana (GOMEZ-HERNANDEZ; JOURNAL, 1993), simulação sequencial indicativa ou com a DSS. Mas uma das maiores vantagens da utilização da Cosimulação Sequencial Direta (CoDSS), esta na melhor reprodução de variogramas e covariogramas das variáveis simuladas uma vez que são utilizados os varigramas e covariogramas das variáveis originais (SOARES, 2005).

Depois de obtidas por DSS as imagens de $Z_1(x)$, o mesmo algoritmo de DSS é agora aplicado a $Z_2(x)$, assumindo uma das imagens previamente simuladas de $Z_1(x)$

com secundária e com uma correlação espacial entre $Z_1(x)$ e $Z_2(x)$ caracterizada pelo correlograma $\rho_{1,2}(h)$. Os valores de $Z_2(x)$ são gerados, em qualquer localização espacial x_0 , a partir de leis de distribuição condicionais aos valores previamente simulados de $Z_1(x)$ e de $Z_2(x)$. As leis de distribuição condicionais são definidas para qualquer localização x_0 , a partir das médias e variâncias locais $[z_2(x_0)]^*$ e $\sigma_{ks}^2(x_0)$, que são obtidas por coestimação de $z_2(x_0)$ com base nos valores $z_2(x_\alpha)$, $z_1^s(x_i)$, $i = 1, N$.

Dado que a variável condicionada $Z_1(x)$ é sobreabundante (imagem previamente simulada), no cálculo da média e variâncias locais $[z_2(x_0)]^*_{cks}$ e $\sigma_{cks}^2(x_0)$ é utilizada a versão de Cokrigagem Colocalizada simples, que é uma combinação linear dos valores selecionados $Z_2(x_\alpha)$ em torno de x_0 e do valor conhecido de $z_1^s(x_0)$, da imagem previamente simulada.

4.4 Aplicações do geoprocessamento na cafeicultura

4.4.1 Variabilidade espacial x cafeicultura

Souza (1992) relatou que a obtenção de informações a respeito da variabilidade dos atributos do solo e das plantas é de grande importância para a avaliação da fertilidade; o levantamento, o mapeamento; e o desenvolvimento de esquemas mais adequados de amostragem, entre outros, visando à melhoria das condições de manejo e o incremento de produtividade das culturas.

O mapa de produtividade pode indicar a localização de áreas críticas em termos de rentabilidade, informações estas importantes para a tomada de decisões. Para tanto há necessidade da utilização de modelos estatísticos capazes de prever a produtividade (OLIVEIRA, 2007).

O mapeamento de produtividade das culturas é uma das fases iniciais da agricultura de precisão. Para as culturas de cereais, os métodos e equipamentos necessários para essa finalidade já são relativamente bem conhecidos, e fazem parte inclusive de equipamentos já comercializados no país. Esse não é o caso de culturas especiais como a de laranja, a de cana-de-açúcar e a de café, para as quais poucos trabalhos sobre a utilização dos

conceitos de agricultura de precisão foram publicados. Embora a produção de café ainda seja de grande importância econômica para o país, os métodos de condução desta cultura não se têm modificado significativamente nas últimas décadas. Acredita-se que novas tecnologias, como as desenvolvidas para a agricultura de precisão, tenham um grande potencial de utilização na cultura de café, principalmente pelo seu alto valor agregado (BALASTREIRE et al., 2001).

Balastreire et al. (2001) realizaram o mapeamento da produtividade de café, colhido mecanicamente, em uma propriedade no município de Pinhal, SP, num talhão de 1,2 ha. Concluíram que a variabilidade espacial dos valores de produtividade é bastante grande, com produtividade mínima de 1,43 t ha⁻¹ e máxima de 18,41 t ha⁻¹.

Leal (2002) realizou o mapeamento da colheita mecanizada do cafeeiro, em uma propriedade do município de Pedregulho, SP, em uma área de 4,0 ha. Os resultados obtidos permitiram concluir que a variabilidade espacial dos valores de produtividade da cultura do café no talhão é bastante grande, com produtividade mínima de 1.284 kg ha⁻¹ e máxima de 6.326 kg ha⁻¹.

Sanchez et al. (2005) estudando a variabilidade espacial da produção de café em diferentes superfícies geomórficas, observou dependência espacial para produtividade do café. Silva et al. (2008) estudando a dependência espacial da produtividade para a cultura do café, em diferentes safras, permitiu inferir que o efeito de bianuidade não interferiu na variabilidade espacial da cultura.

Oliveira (2007) mapeou a produtividade do café conilon, por meio de colheita manual, durante as safras de 2005 e 2006 em uma área experimental do INCAPER na Fazenda Bananal do Norte, localizada no município de Cachoeiro de Itapemirim – ES. Os resultados obtidos mostraram uma alta variabilidade espacial da produtividade para ambos os anos, com produtividade mínima de 2.701 kg ha⁻¹ e máxima de 14.421 kg ha⁻¹, para o ano de 2005, e mínima de 3.426 kg ha⁻¹ e máxima de 10.826 kg ha⁻¹, para o ano de 2006.

Oliveira et al. (2011) estudando a variabilidade espacial do estado nutricional do café conilon, utilizando os teores dos nutrientes na folha, encontrou forte dependência espacial para maioria dos nutrientes, com exceção do N e P, possibilitando a confecção de mapas de aplicação diferenciada e localizada de fertilizantes.

Rezende et al. (2011) estudando áreas com café arábica adubadas via fertirrigação e em sistema tradicional, observou que nas plantas irrigadas e não irrigadas, a condutividade elétrica do solo apresentou dependência espacial, tendo sido possível o desenvolvimento de mapas da distribuição espacial da salinidade.

4.4.2 Sensoriamento remoto na cafeicultura

A estimativa da produtividade utilizando imagens de satélite já foi o objetivo de vários trabalhos, mas em sua grande maioria tratou-se de culturas anuais. Para a cultura do café, o sensoriamento remoto tem sido usado, mas com certas limitações. Em trabalho correlacionando as variáveis da cultura cafeeira com suas respostas espectrais em imagens TM/Landsat-5, Vieira et al.(2000b) concluíram que a cultura apresenta resposta espectral bastante complexa e sofre alterações ao longo do ano. Os autores ainda aconselham a associação de produtos de sensores remotos de maior resolução espacial, para permitir o levantamento e monitoramento da resposta espectral em cafeeiros, em regiões para as quais o imageamento orbital não é beneficiado.

Epiphany et al. (1994), estudando as relações entre variáveis biofísicas de cafezais e sua resposta espectral em imagens TM/Landsat-5, concluíram que os parâmetros culturais referentes às características biofísicas da planta foram mais bem correlacionados com a refletância do que os parâmetros relativos ao substrato ou os parâmetros geomorfológicos do terreno.

Em uma área-piloto representativa da cafeicultura da região do Sul de Minas Gerais, usando imagens orbitais TM/Landsat-5, Hurtado et al. (2003) concluíram que, para a região em estudo mediante treinamento, para a classificação supervisionada por máxima verossimilhança e uma análise temporal das imagens, podem-se estimar de maneira mais precisa as áreas com ocupação cafeeira, ajudando na detecção de pequenas variações e dando uma maior segurança na determinação de áreas já ocupadas com a cultura.

Para que seja viável a utilização do sensoriamento remoto na identificação da variabilidade da produtividade, torna-se necessário, para cada cultura, a identificação da época mais adequada na tomada dos dados. Trabalhos em lavouras cafeeiras

no centro-sul do Estado de Minas Gerais com uso de imagens Landsat 5 e 7, Moreira et al. (2003) observaram que, embora o café seja uma cultura perene, a melhor época para o mapeamento desta cultura, através de dados orbitais, é nos meses mais secos, em que o contraste espectral de áreas cafeeiras e outros alvos de ocupação do solo é maior.

Moreira et al. (2010) utilizando imagens de sensoriamento remoto e técnicas de geoprocessamento, desenvolveram metodologia que possibilitou identificar e mapear as áreas de café cultivadas nos Estados de Minas Gerais e São Paulo para o ano de 2007, identificando a melhor época de aquisição das imagens para o mapeamento do café em Minas Gerais no período seco (junho a setembro) e para o Estado de São Paulo, um período mais restrito (agosto a setembro).

Para a cultura do café até então, o sensoriamento remoto tem sido usado, principalmente, no mapeamento e caracterização de áreas produtivas, com novos estudos abordando diferentes assuntos relacionados ao agroecossistema cafeeiro. Rosa (2007) analisou o potencial de um modelo agrometeorológico-espectral para estimar a produtividade do café. Campos et al. (2009) em estudos com a cultura encontrou que, embora apresente variações no comportamento espectral devido a fatores como espaçamento, idade e época do ano, a cultura pode ser identificada e mapeada em imagens de satélites com razoável precisão, desde que existam informações complementares, quer seja de levantamentos subjetivos ou de técnicos que trabalham no local de interesse. E ainda, Sousa et al. (2011) utilizando imagens do sensor LISS 3 e com aplicação de geoprocessamento, mostraram-se eficazes no mapeamento de café da região do Extremo Oeste Baiano, servindo como subsídio na estimativa e previsão de safra.

5 MATERIAIS E MÉTODOS

5.1 Caracterização da área experimental

5.1.1 Localização e edafologia

O trabalho foi realizado em uma área comercial de café conilon localizada no Distrito de Nestor Gomes, Rodovia ES 381, km 28, no Município de São Mateus, Norte do Estado do Espírito Santo, que abrange os Sítios Lagoa do Vinhático, Córrego Grande e Córrego Grande & Cedro, cujas coordenadas geográficas centrais são: 18°45'38" de latitude Sul e 40°04'40" de longitude W de Greenwich e altitude média de 78 m. O solo da área é classificado como LATOSSOLO VERMELHO-AMARELO Distrófico, textura franco argiloso arenosa com relevo plano a suave ondulado, segundo o Sistema Brasileiro de Classificação de Solos (EMBRAPA, 2006).

A Figura 3 ilustra a localização da lavoura comercial no município de São Mateus no Estado do Espírito Santo com a caracterização da área experimental onde foram coletados os dados da produção do café conilon.

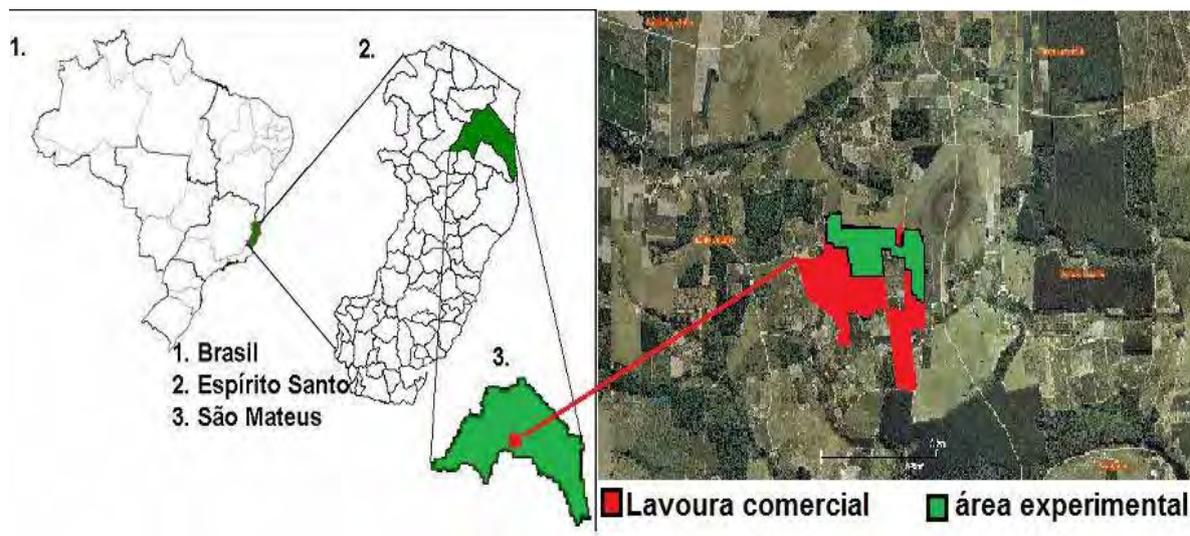


Figura 3. Localização da lavoura comercial no município de São Mateus no Estado do Espírito Santo com a caracterização da área experimental para coleta dos dados.

Fonte: Adaptado do GEOBASES - Sistema Integrado de Bases Geoespaciais do Estado do Espírito Santo – (2008)

5.1.2 Dados climáticos

O clima, segundo a classificação de Köppen, é do tipo Aw, com estação seca no inverno e verão quente e chuvoso. Os dados climáticos baseados numa série histórica compreendida entre os últimos 30 anos apresentaram temperatura média anual de 24,8°C, com temperatura média do mês mais frio de 19,8°C, do mês mais quente de 29,8°C e precipitação média anual acumulada de 1.288 mm. Esses dados climáticos foram obtidos da estação meteorológica Inc_013, coordenada pelo INCAPER. Baseado nos dados coletados de um pluviômetro localizado na sede das propriedades, a Figura 4 ilustra a precipitação pluviométrica (mm) ocorrida na área de estudo entre abril/2009 a março/2010, período na qual os fatores climáticos influenciaram para a colheita de 2010. De acordo com a Figura 4, observa-se que para o período em estudo, a estação seca ocorreu entre os meses de maio a setembro, totalizando 5 meses de estiagem, comum para a região, porém analisando os últimos anos, a duração desta estação seca aparenta aumentar. Observa-se ainda, um período de baixa precipitação entre os meses de dezembro e janeiro, não muito comum na região, colaborando para uma precipitação anual de 798 mm, consideravelmente baixa para a cultura. Esses meses

normalmente apresentam as maiores precipitações, que são fundamentais para a cultura do café conilon na região, ocorrendo nesse período grande parte do enchimento dos grãos. Para que esse processo fisiológico ocorra de forma satisfatória, à planta exige do ambiente uma lâmina d'água suficiente para o ganho de massa na colheita.

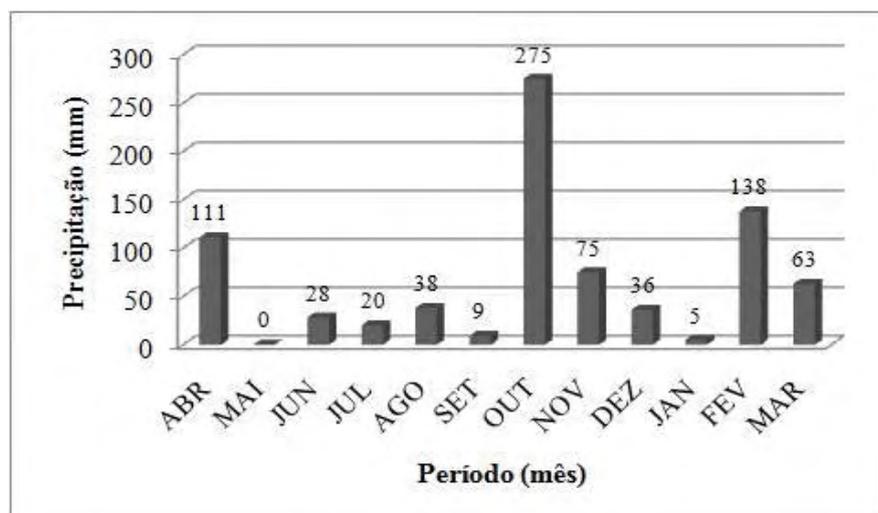


Figura 4. Precipitação pluviométrica ocorrida para o período de abril/2009 a março/2010, baseada na medição de pluviômetro instalado na área em estudo.

Desta forma, para o cultivo de culturas como o café conilon, quando se objetiva uma alta produtividade, as condições climáticas de precipitação pluviométricas da região são consideradas insuficientes, principalmente pela má distribuição, como observado pelo gráfico da Figura 4. Havendo então necessidade da aplicação de lâmina d'água auxiliar, o que torna assim, indispensável o uso de irrigação no manejo hídrico da cultura. Para a área em questão, a lâmina d'água auxiliar é fornecida com sistema de irrigação localizada por microaspersão e vazão média de 16 l h^{-1} . O manejo hídrico com turno de rega variado é baseado na curva de retenção de água no solo e na evapotranspiração local, o que em médias mensais, compreende a 80 mm mês^{-1} para os meses mais quentes e 50 mm mês^{-1} para os meses com menor evapotranspiração.

5.2 Espécie cultivada

A espécie de café cultivada é a *Coffea canephora* Pierre, Var. conilon, ilustrada na Figura 5. É a variedade de café com maior difusão na região Norte do Estado do Espírito Santo, por aceitar as condições climáticas locais de temperaturas mais elevadas e de maior oscilação da precipitação pluviométrica ao longo do ano. Recomenda-se o plantio em áreas com altitudes até 400 m.



Figura 5. Vista parcial de um dos talhões da área comercial de *Coffea canephora* utilizada em estudo, com destaque para as fileiras com número médio de 4 hastes (ramos plagiotrópicos) por planta e coloração amarelada de algumas ramos, indicando extração de nutrientes pela produção.

Fonte: Quartezani (2010).

5.3 Malha amostral

Na lavoura comercial com *Coffea canephora*, foram demarcados os pontos de amostragem, definidos como células amostrais, situados dentro de uma área irregular de aproximadamente 185.670 m² (18,567 ha). Os pontos foram espaçados a diferentes distâncias (não equidistantes), formando uma grade irregularmente representativa da área. Em 5 regiões ao longo da malha foi feito um adensamento dos pontos, com a

amostragem de 5 pontos a uma distância menor, para evitar que os variogramas apresentassem Efeito Pepita Puro, nos casos em que o alcance ou a dependência espacial da variável em estudo fossem menores que a distância de amostragem. Cada célula foi constituída pela amostragem de 3 plantas, na mesma fileira, para a coleta da variável produção do café conilon, constituindo portanto, uma amostragem composta, totalizando 87 células amostrais. O georreferenciamento correspondeu ao centro de cada célula (planta do meio) e as coordenadas foram obtidas com o auxílio um GPS topográfico. Foi utilizado o sistema de coordenadas UTM (Universal Transverso de Mercator) com Datum WGS-84. As informações tomadas nas células amostrais foram associadas as suas respectivas coordenadas geográficas com o auxílio de uma planilha eletrônica. A Figura 6 ilustra o Modelo Numérico de Elevação (MNE) da área em estudo com o esquema de distribuição dos pontos na malha amostral.

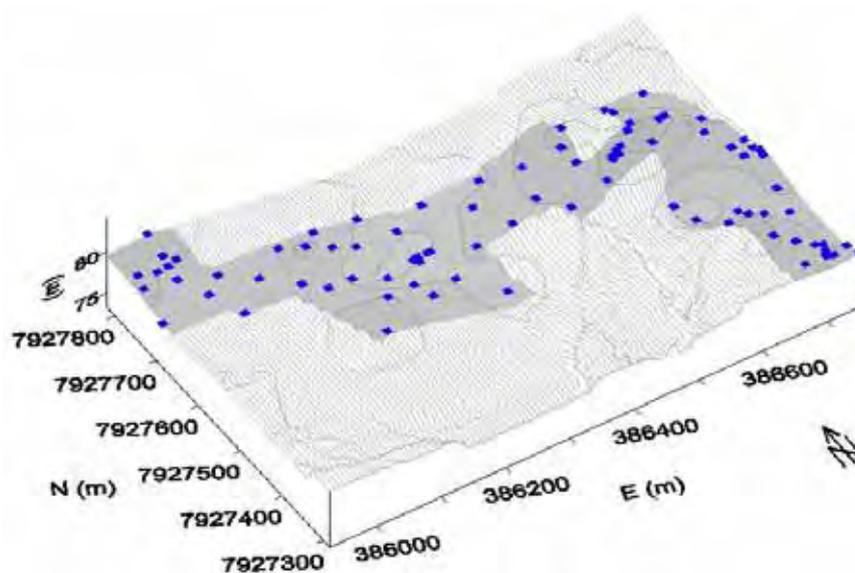


Figura 6. Modelo Numérico de Elevação da área em estudo com a distribuição dos pontos amostrais na malha.

5.4 Determinação da variável café maduro (CM)

A variável produção de café maduro (CM) foi determinada a partir da colheita da produção de café úmido (verde e maduro) proveniente da safra de 2010. A colheita

foi iniciada em abril, obedecendo às condições exigidas pelo fruto, sendo feita quando os grãos iniciaram o amadurecimento (Figura 7A), o que na região Norte do ES, para o café conilon, ocorre normalmente nos meses de abril e maio. Os grãos de café de cada célula amostral (composto de três plantas) foram derrichados manualmente em peneiras (Figura 7B), posteriormente colocados em sacos devidamente identificados (Figura 7C) e por fim, foram pesados em balança comercial (Figura 7D) para a determinação da variável (CM) em kg.



Figura 7. Processos de obtenção da variável CM: (A) estágio de maturação dos frutos de café úmido na época da colheita; (B) colheita manual com derriça em peneira; (C) esquema de identificação das amostras colhidas; (D) Pesagem das amostras de café úmido em balança comercial.

Fonte: Quartezani (2010).

5.5 Aquisição da imagem de satélite

A imagem de sensoriamento remoto utilizada para o desenvolvimento do trabalho foi adquirida pelo site do (INPE) Instituto Nacional de Pesquisas Espaciais (<http://www.dgi.inpe.br>), com a seguinte descrição:

- Imagem do satélite CBERS 2B, sensor CCD, bandas 2 (verde), 3 (vermelho) e 4 (infravermelho), Orbita Ponto 148/121, data da aquisição 24/02/2010, no período seco, resolução espacial de 20 metros.

5.6 Programas computacionais

Para a tabulação, análise estatística e correlação dos dados, foram utilizados os programas Excel (MICROSOFT, 1998), o MÓDULO geoDATA do geoMS v. 1.0 (CMRP, 2000) e o Statistica 7.0 (STAT SOFT, 2001). Para análise geoestatística, o programa adotado foi o geoMS v. 1.0 com a utilização dos MÓDULOS geoVAR; geoVAG; geoMOD, geoKRIG e geoDSS. No Idrisi 15.0 Andes (EASTMAN, 2006) foram feitos todos os pré-tratamentos da imagem de satélite, para os cálculos dos índices de vegetação. A parte gráfica visual, com os mapas e o modelo numérico de elevação da malha irregular, foram construídos nos programas Surfer 8.0 (GOLDEN SOFTWARE, 2002) e no MÓDULO geoVIEW do geoMS.

5.7 Processamento digital da imagem

Para a obtenção de informações temáticas dos alvos contidos na área imageada, todo o tratamento da imagem orbital foi realizado no Idrisi 15.0 Andes. Esse procedimento foi basicamente dividido em duas etapas: pré-processamento e transformação da imagem.

5.7.1 Pré-processamento

No pré-processamento, foram realizados a importação das bandas 2, 3 e 4 da imagem CBERS 2B, o registro ou georreferenciamento e o recorte da área de estudo das bandas.

A primeira etapa consistiu na importação das bandas da imagem, com a conversão do arquivo original, que estava em formato *.geotiff*, para o formato *raster* (“*.rst*”), reconhecido pelo IDRISI.

Para que a área de estudo fosse geoidentificada corretamente nas bandas, foi feito a correção geométrica ou georreferenciamento. A correção geométrica tem a função de reorganizar os *pixels* da imagem em relação a um determinado sistema de projeção cartográfica. Ela objetiva minimizar as distorções geométricas, provenientes das características do sensor utilizado e das variações decorrentes do movimento do mesmo durante a passagem sobre o alvo (LUIZ et. al., 2003). Este procedimento foi realizado com o registro das bandas, utilizando como pontos de controle as coordenadas reais que foram obtidas do levantamento planimétrico da área.

Para à redução da dimensionalidade dos dados e o realce das informações desejadas, foi feito o recorte da área de estudo nas bandas, utilizando as coordenadas dos vértices da área, nos limites ($X_{Min.}$; $X_{Máx.}$ e $Y_{Min.}$ e $Y_{Máx.}$) das bandas. Como o formato da área é irregular, foi preciso gerar uma máscara no sufer 8.0, aplicando a função “*Blank*” a uma grade da área interpolada e as coordenadas do perímetro da área coletadas no levantamento planimétrico. A máscara então foi importada pelo IDRISI e combinada com cada banda recortada da imagem, utilizando a ferramenta de operação matemática “*Overlay*”.

5.7.2 Transformação

O tratamento de transformação consistiu em condensar a informação contida nas bandas em índices espectrais, ou ainda, índices de vegetação (IVs). Um índice de vegetação resulta da combinação dos valores de refletância em dois ou mais intervalos de comprimento de onda, possuindo certa relação com a quantidade e o estado da vegetação em

uma dada área da superfície terrestre (RIZZI, 2004). O seu uso vem sendo empregado para encontrar comportamentos diferentes na cobertura vegetal e uso da terra. Muitos são os índices utilizados na transformação de imagens do sensoriamento remoto, para este trabalho dentre os índices espectrais determinados, estão:

- Índice de Vegetação da Diferença de Verde Normalizado (GNDVI):

$$\text{GNDVI} = (\text{IV} - \text{V}_d / \text{IV} + \text{V}_d) \quad (7)$$

onde:

IV: valor numérico do pixel da banda do infravermelho;

V_d : valor numérico do pixel da banda do verde.

- Razão entre o Verde e o Infravermelho (GNIR):

$$\text{GNIR} = (\text{V}_d / \text{IV}) \quad (8)$$

- Banda Infravermelho normalizada (IV_n):

$$\text{IV}_n = \text{IV} / (\text{V}_m + \text{V}_d + \text{IV}) \quad (9)$$

onde:

V_m : valor numérico do pixel da banda do vermelho.

- Índice de Vegetação da Diferença Normalizada (NDVI):

$$\text{NDVI} = (\text{IV} - \text{V}_m / \text{IV} + \text{V}_m) \quad (10)$$

- Razão entre o Vermelho e Infravermelho (RNIR):

$$\text{RNIR} = (\text{V}_m / \text{IV}) \quad (11)$$

- Banda Verde normalizada (VD_n):

$$VD_n = V_d / (V_m + V_d + IV) \quad (12)$$

- Banda Vermelho normalizada (VM_n):

$$VM_n = V_m / (V_m + V_d + IV) \quad (13)$$

Os resultados dos índices gerados em formato *raster* foram convertidos para um vetor de pontos e exportados com extensão *XYZ* para os programas Excel e Statística 7.0 onde foram feitas as correlações com a variável CM.

5.8 Análise dos dados

A primeira fase de avaliação do dado de produção estudado se restringiu à análise exploratória descritiva, com a realização de um resumo estatístico. Posteriormente, aplicação da geoestatística para análise da variabilidade espacial, possibilitando estimativas em locais não amostrados por krigagem e a realização de um conjunto de imagens equiprováveis da realidade por simulação e cosimulação, para a inferência de incertezas.

5.8.1 Análise descritiva

Nesta análise, a exploração dos dados foi realizada no intuito de identificar, descrever e avaliar algumas estatísticas de interesse como as medidas de posição e dispersão e correlação, utilizando a análise estatística descritiva proposta por Vieira (2000a).

5.8.2 Análise geoestatística

Os dados foram submetidos à análise geoestatística no intuito de verificar a existência da dependência espacial, com o ajuste do variograma clássico de Matheron, definido na equação 1.

Segundo Guimarães (2004), a escolha do modelo de variograma a ser utilizado é um dos aspectos mais importantes da geoestatística. Todos os cálculos dependem do modelo de variograma ajustado e, conseqüentemente, se o modelo ajustado não for apropriado, todos os cálculos seguintes conterão erros que poderão afetar as inferências.

Definidos os parâmetros efeito pepita, alcance e patamar, a estimativa dos valores em posições não amostradas no campo, foi obtida pela técnica de interpolação por krigagem definida na Equação 5. A krigagem foi utilizada para a estimativa da variável CM.

Com a malha de pontos interpolados, tem-se um maior detalhamento da área em estudo, e uma melhor visualização do comportamento da variável na região, devido ao aumento do número de observações. A grade interpolada foi utilizada para a criação de mapa temático da variável CM, com a obtenção desse mapa possibilitando o estabelecimento de zonas de manejo.

5.8.3 Análise de simulação

A metodologia proposta consiste na estimação e simulação da variável produção de café (CM) baseado nos procedimentos de interpolação por krigagem, estocásticos de Simulação e Cosimulação Sequencial Direta e modelos de correionalização local, utilizando Índices de Vegetação (IVs) como imagens secundárias.

Os critérios para aplicação da metodologia foram os seguintes: i) a influência das observações de campo prevalece sobre os dados secundários e é proporcional à proximidade a essas amostras, ou ainda, a influência dos dados de campo na estimação da produção de café é máxima quando o ponto a estimar coincide com uma observação de campo e vai diminuindo com o aumento da distância; ii) a influência dos dados secundários depende da sua correlação global e/ou local (de acordo com o método de CoDSS) com os dados

primários, ou seja, a influência dos dados secundários é maior em regiões de maior correlação do que em regiões de baixa correlação. Para a CoDSS colocada com correlação local (CoDSS_CCL), este segundo critério exige o cálculo das correlações locais e a estimativa dos mapas de correlação para os diferentes IVs.

A simulação estocástica de imagens da variável dominante CM - $Z_1(x)$ foi efetuada através do método de Simulação Sequencial Direta, condicionada aos dados experimentais e através do método de Cosimulação Sequencial Direta Colocalizada, com correlação global (CoDSS_CCG) e local (CoDSS_CCL), utilizando-se cada imagem simulada dos IVs - $Z_2(x)$ como imagem secundária.

A partir dos vários mapas equiprováveis da variável CM, pode-se representar em cada ponto o valor de CM mais provável assim como as zonas de maior e menor incerteza. Se escolhermos $Z_1(x)$ como variável primária, ou seja, a variável mais importante ou que evidencia uma maior continuidade espacial, a Simulação e Cosimulação Sequencial Direta é resumida nas seguintes etapas: (Soares, 2001):

1. Escolha de uma sequência aleatória de nós de uma malha regular que permita a visita de todos os nós.
2. Em cada nó x_u :
3. Simulação do valor de $z^s_{I_1}(x_u)$ utilizando o algoritmo de Simulação Sequencial Direta (DSS):
 - Estimação da média e variância de $Z_1(x)$, $Z_1(x_u)^*$ e $\sigma^2_{sk}(x_u)$ por krigagem simples (SK). Reamostrar localmente o histograma de $Z_1(x_u)$, utilizando, por exemplo, uma transformação gaussiana (ϕ_I) da variável primária $Z_1(x)$; cálculo de $y(x_u)^* = j_I(Z(x_u)^*)$;
 - Geração de um número aleatório p a partir de uma lei uniforme $U(0,1)$;
 - Geração do valor y^s a partir de $G(y(x_u)^*, \sigma^2_{sk}(x_u))$:

$$y^s = G^{-1}(y(x_u)^*, \sigma^2_{sk}(x_u), p);$$

- Retorno do valor simulado da variável primária $z^s_{I_1}(x_u) = \phi^{-1}_I(y^s)$.

4. O mesmo algoritmo DSS é aplicado seguidamente para a simulação da variável secundária $Z_2^s(x_u)$ utilizando agora o estimador krigagem simples Colocalizada para a estimação de $Z_2(x_u)^*$ e $\sigma_{2sk}(x_u)$:

$$[z_2(x_0)]^*_{ckz} = \sum_{\alpha=1}^N \lambda_{\alpha} [z_2(x_{\alpha}) - m_2] + \lambda_{\beta} [z_1^s(x_0) - m_1] + m_2 \quad (14)$$

- Cálculo de $y(x_u)^* = \varphi_2(z_2(x_u)^*)$, em que φ_2 é a transformada gaussiana da variável secundária $Z_2(x)$. Geração de um valor p a partir de uma lei uniforme $U(0,1)$;
- Geração do valor y^s a partir de $G(y_2(x_u)^*, \sigma_{2sk}(x_u))$:

$$y^s = G^{-1}(y_2(x_u)^*, \sigma_{2sk}(x_u), p);$$

- Retorno do valor simulado da variável secundária $Z_2^s(x_u) = \varphi^{-1}_2(y^s)$.

5. Continuar para o nó seguinte até todos os nós estarem simulados.

5.8.3.1 Cokrigagem colocalizada

Em vez da utilização da Cokrigagem, que implica a modelação de variogramas cruzados, recorreu-se à Cokrigagem colocalizada, com a aplicação do conhecimento das covariâncias espaciais dos dados primários e entre os dados secundários e primários. De acordo com a aproximação de Markov-Bayes (GOOVAERTS, 1997), apenas é necessário estimar as covariâncias dos dados primários e os coeficientes de correlação entre os dados primário e secundário, que se obtêm no correlograma entre os dados primário e secundário para $h=0$, sendo aproximadas pelas seguintes relações:

$$C_{12}(h) \approx [C_{12}(0) / C_{11}(0)] C_{11}(h) \text{ ou } \rho_{12}(h) \approx \rho_{12}(0) \rho_{11}(h) \quad (15)$$

ou seja, apenas é necessário a determinação do variograma ou correlograma $\rho_{11}(h)$ da variável principal e do coeficiente de correlação $C_{12}(0)$ entre a variável primária e a secundária.

Este método é utilizado quando a variável secundária é conhecida em todos os pontos que pretendemos estimar, como é o caso dos IVs, provenientes de imagens de satélite.

5.8.3.2 Modelo de correionalização local

Para a aplicação da Cosimulação Sequencial Direta colocada com correlação local (CoDSS_CCL) foi necessário gerar modelos de correionalização local para cada índice de vegetação.

Os modelos de correionalização baseiam-se na medição indireta das correlações locais entre as escassas, mas fiáveis observações de campo da variável primária e os IVs das imagens de satélite (variável secundária) disponível pra toda a área de estudo. Dado que a correlação não é homogênea para toda a área de estudo, e que os dados primários são poucos e distribuídos irregularmente pela área, foram calculadas as correlações locais, de modo a ter em conta as características específicas do problema, tanto no que depende da variabilidade nas correlações como no que diz respeito à distribuição dos dados primários. No cálculo das correlações locais, utilizou-se um algoritmo do tipo “janela móvel” que, para um dado raio de busca, calcula os coeficientes de correlação.

Em volta de cada amostra experimental, é selecionado um conjunto de observações vizinhas de acordo com um dado raio de busca. Baseado nessas observações é calculado o coeficiente de correlação e esse valor local é alocado à amostra central. A dimensão do raio é escolhida de modo a garantir um número significativo de pontos dentro do círculo, respeitando, porém, o caráter regional ou local das estatísticas. Para cada um dos 87 pontos amostrais da variável CM, foram calculadas as correlações locais entre os dados de campo e os correspondentes IVs para um determinado raio. Foram testados vários raios de busca dentro dos limites de dimensões da área de estudo.

Após o cálculo das correlações locais, assim como para os dados primários, foram ajustados variogramas experimentais omnidirecionais para as correlações, dado que não foi detectado nenhum tipo de anisotropia. Modelado os variogramas, com o objetivo de efetuar a sua distribuição no espaço, estimou-se as correlações locais por meio da

krigagem. A estimativa permitiu determinar as correlações médias num ponto, a partir das informações existentes. Desta forma foram obtidos superfícies (mapas) de correlação para cada um dos IVs analisados.

5.8.3.3 Validação das simulações

Segundo Soares (2006), do ponto de vista quantitativo, com um modelo de simulação pretende-se reproduzir, na imagem simulada, a variabilidade do fenômeno em estudo basicamente através de duas estatísticas: a função de distribuição de $Z(x)$ – $F_z(z) = \text{prob}\{Z(x) < z\}$, que garante a frequência das diferentes classes do histograma e variograma $\gamma(h)$ que reproduz a continuidade espacial de $Z(x)$. Concretamente, se designarmos por $Z_c(x)$ o conjunto de valores simulados e por $Z(x_\alpha)$, $x_\alpha = 1, \dots, n$, os n valores experimentais, a imagem simulada deve cumprir as seguintes condições:

1. Para qualquer valor z : $\text{prob}\{Z(x_\alpha) < z\} = \text{prob}\{Z_c(x) < z\}$;
2. $\gamma(h) = \gamma_c(h)$, sendo $\gamma(h)$ e $\gamma_c(h)$ os variogramas dos valores experimentais e dos valores simulados, respectivamente;
3. Condicionamento dos valores experimentais: em qualquer ponto experimental x_α , o valor $Z(x_\alpha)$ e o valor simulado $Z_c(x_\alpha)$ coincidem - $Z(x_\alpha) = Z_c(x_\alpha)$. Isso significa que, além de ter a mesma variabilidade, a imagem simulada passa pelos pontos experimentais. Passar pelos pontos experimentais significa não só a coincidência espacial dos valores das amostras e dos valores simulados, mas também a influência dos valores das amostras nos mapas simulados que é determinada pela maior ou menor continuidade estrutural denunciada nos modelos dos variogramas.

5.8.3.4 Mapas simulados

Satisfeito os pressupostos impostos pelos métodos de DSS e CoDSS, foram gerados os mapas da média e variância provenientes da realização de 50 simulações

para cada método, objetivando a estimação da variável primária e a identificação e quantificação de áreas de incertezas associadas à estimação da variável CM, respectivamente.

6 RESULTADOS E DISCUSSÃO

6.1 Variável de planta usada como dado primário

6.1.1 Análise exploratória

A Tabela 1 apresenta, além das estatísticas básicas de posição e de dispersão, os coeficientes de assimetria (C_s), de variação (CV) e normalidade para a variável de planta CM.

Tabela 1. Análise estatística descritiva da variável de planta CM em estudo

Variável	Parâmetros									
	n ¹	Min	Máx	Média	Md ²	S	CV ³	C_s ⁴	S-W ⁵	K-S ⁶
CM ⁷	87	0,10	39,90	19,16	21,20	11,11	58,03	-0,12	0,001*	0,106 ^{ns}

¹números de pontos; ²mediana; ³coeficiente de variação; ⁴coeficiente de assimetria; ⁵distribuição normal pelo teste de Shapiro-Wilk (S-W) ao nível de 5% de probabilidade; ⁶distribuição normal pelo teste de kolmogorov-Smirnov (K-S); ⁷produção de café maduro; *significativo a 5% pelo teste de S-W, indicando distribuição não normal dos dados; ^{ns} não significativo a 5% pelo teste de K-S, indicando distribuição normal dos dados.

Nas medidas estatísticas de posição a média apresentou menor valor que a mediana, indicando uma assimetria negativa, porém essa diferença foi mínima, com o valor do coeficiente de assimetria próximo de zero ($C_s = - 0,12$). Quanto mais próximo de 0

(zero) for o valor do Cs, assim como quanto mais próximos forem os valores da média e mediana, segundo Libardi et al. (1996) e Costa Neto (1990), tanto mais próximo à distribuição estará normal, como confirmado pelo teste kolmogorov-Smirnov (K-S). Porém esta hipótese não foi aceita pelo teste de Shapiro-Wilk (S-W) ao nível de 5% de probabilidade, que indicou distribuição não normal dos dados.

Segundo Eguchi (2001), se a distribuição não é normal, a média aritmética é muito influenciada por valores extremos, tornando-se uma medida de tendência central não representativa do conjunto de dados. Porém, a normalidade dos dados não é uma exigência da geoestatística para sua aplicabilidade, é apenas conveniente que a variável não apresente extremidades da distribuição muito longas, para não comprometer as análises (CRESSIE, 1991).

O coeficiente de variação (CV = 58,03 %) apresentado foi muito alto (> 30 %), segundo a classificação proposta por Pimentel-Gomes (1987). Este valor de CV indicando uma alta variabilidade da produção mostra que o manejo da cultura sofre alterações ao longo da área, sendo essas alterações em função da divisão da área em talhões, que acabam correspondendo a zonas de manejo onde, segundo Luchiari Junior et al. (2000), são áreas numa propriedade agrícola ou talhão que possuem variáveis com menor heterogeneidade. Na Figura 8 tem-se o histograma com a distribuição de frequência da variável primária CM.

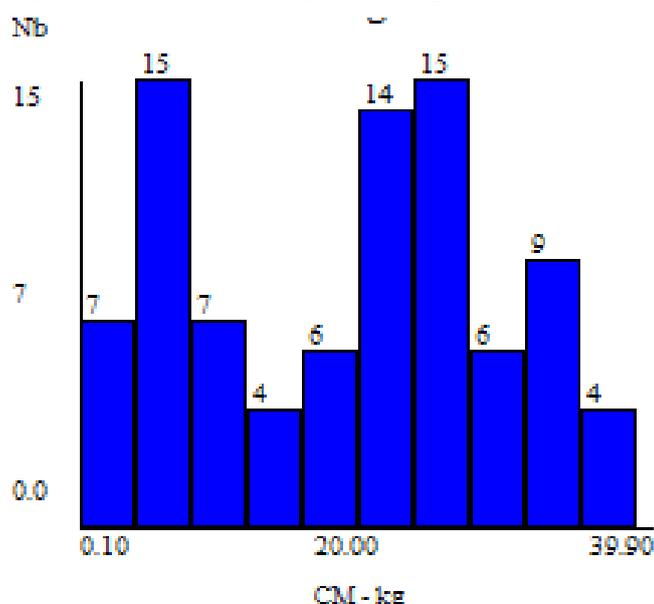


Figura 8. Histograma da variável de planta Café Maduro (CM).

6.1.2 Análise da continuidade espacial da variável CM

Na Figura 9 temos os modelos teóricos ajustados aos variogramas experimentais da variável primária CM, para as direções N-S (0°), NE-SW (45°), E-W (90°) e NW-SE (-45°).

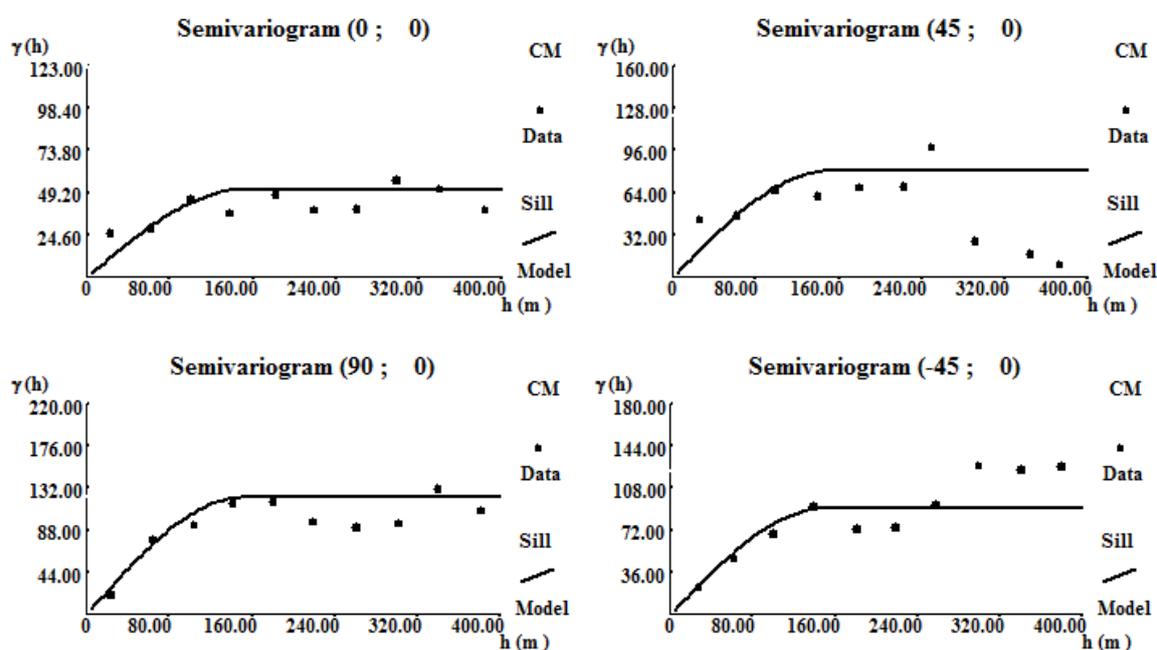


Figura 9. Variogramas da variável CM para as direções N-S (0°), NE-SW (45°), E-W (90°) e NW-SE (-45°), respectivamente.

Observa-se que a variável CM apresentou como parâmetros, modelo Esférico (Esf), valor zero de Efeito Pepita ($C_0 = 0$) e uma alcance(a) de 150 metros, para os variogramas nas 4 direções analisadas.

Segundo Soares (2006), a continuidade espacial de um recurso natural pode variar com as diferentes direções do espaço, e ainda, na situação em que a variável em estudo se estende preferencialmente, de um modo mais contínuo, numa direção particular, da origem a uma estrutura anisotrópica. Na Figura 9 verifica-se que os variogramas tem ajuste ao

mesmo modelo, porém com patamares diferentes, entre as direções, o que classificaria uma anisotropia zonal, onde a continuidade espacial ao longo de um estrato contrasta significativamente com a variabilidade entre estratos (SOARES, 2006).

Porém os ajustes dos variogramas encontrados foram influenciados pela disponibilidade de pontos em cada direção, tanto que, os ajustes com patamares mais bem definidos foram encontrado para o variograma E-W (90°), seguido do NW-SE (-45°), devido a maior disponibilidade de pontos amostrais nestas direções. Já os variogramas N-S (0°) e NE-SW (45°) não atingiram o patamar, pelo fato da malha amostral apresentar a menor dimensão nestas direções. Este mesmo comportamento da continuidade espacial foi encontrado para as imagens dos IVs utilizados como dados secundários, com os variogramas ajustando ao mesmo modelo e alcance.

Esta continuidade espacial de 150 metros encontrada pelos variogramas, corresponde a um valor próximo das dimensões (comprimento e largura) médias dos talhões de café na área. Na prática, isso implica num possível manejo diferenciado em função dos talhões. Por esse motivo, e ainda, devido a insuficiência de pontos em algumas direções e de posse dos variogramas das imagens secundárias, por analogia, admitiu-se que o variograma omnidirecional modelizado para a variável CM expressa a continuidade espacial característica de um processo aleatório isotrópico. Sendo assim, todos os processos subsequentes foram assentados na isotropia indicada pela estrutura do variograma omnidirecional.

6.1.3 Estimação da variável CM

Ajustado o variograma teórico aos dados experimentais, foi possível determinar a continuidade espacial da produção do café utilizando a krigagem como estimador. A Figura 10 apresenta o mapa e histograma da variável CM interpolada por krigagem.

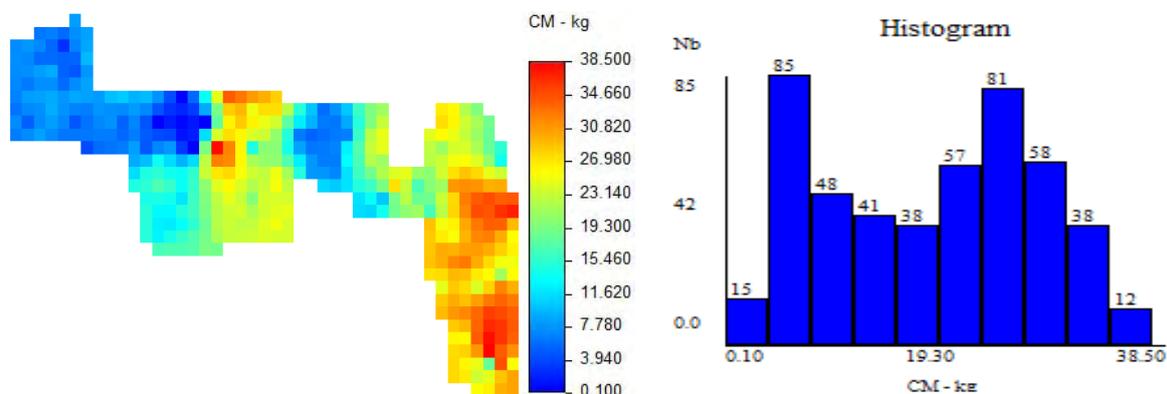


Figura 10. Mapa e histograma da krigagem para a variável primária CM.

Comparando o histograma da Figura 10, com o histograma da variável CM, da Figura 8, nota-se que as distribuições apresentam comportamentos semelhantes, com a krigagem estimando a realidade da variável CM. E ainda, as medidas estatísticas de posição e dispersão da krigagem, apresentadas na Tabela 2, e dos dados de campo, são semelhantes.

Tabela 2. Estatísticas dos valores estimados por krigagem da variável CM

Variável	Estatísticos			
	Média	Mediana	Coeficiente de Variação	Assimetria
CM	19,16	21,20	57,7	-0,12

A krigagem é um estimador ótimo por ser não tendenciosa e com variância mínima. Sendo uma média móvel ponderada, o interpolador promove uma suavização na distribuição dos valores, como se observa no histograma da Figura 10 (VIEIRA, 1998). Isso porque os ponderadores do estimador de krigagem são calculados pelo critério de minimização da variância dos erros. Porém, segundo Soares (2006), esta mesma variância pode ser utilizada para inferir a qualidade do estimador e, inclusivamente, pode ser quantificada na medição do erro, permitindo o cálculo de zonas de incerteza em torno dos valores estimados, utilizando modelos geoestatísticos de simulação.

6.2 Imagens do IVs usados como dados Secundários

A Figura 11 apresenta as imagens de satélites transformadas em IVs.

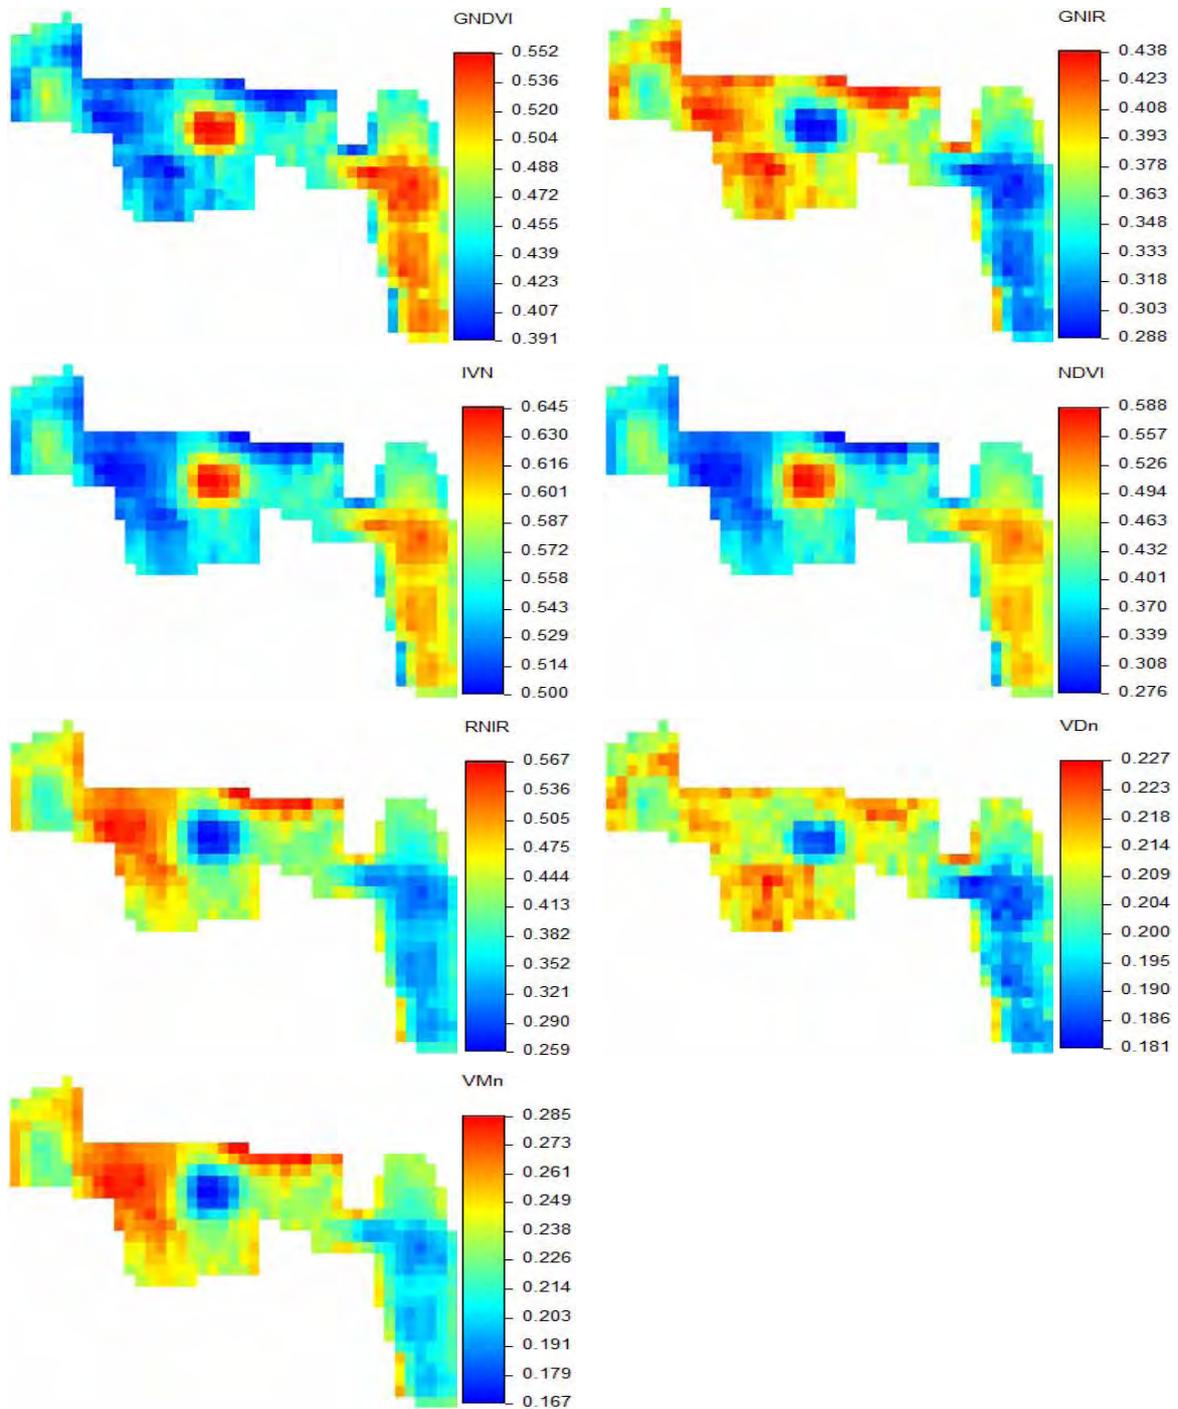


Figura 11. Mapas dos IVs usados como dados secundários.

Os IVs expressos nas imagens da Figura 11, evidenciam a existência de duas regiões que diferenciam-se das demais ao longo da área de estudo. As duas regiões, uma ao centro da área e a outra mais a direita do mapa, corresponde aos valores máximos e mínimos de acordo com cada IV. Ainda numa análise visual, comparando cada mapa da Figura 11 com o mapa de krigagem da variável CM na Figura 10, temos que essas duas regiões especificadas correspondem as áreas de maior produção de café no mapa de krigagem. O mesmo comportamento ocorre para o restante da área, indicando uma alta correlação, seja ela positiva (+) ou negatia (-) entre os IVs e a variável CM. Esta correlação espacial é confirmada com os variogramas dos IVs ajustando ao mesmo modelo e alcance da variável CM, como mostra as Figura 12, 13 e 14.

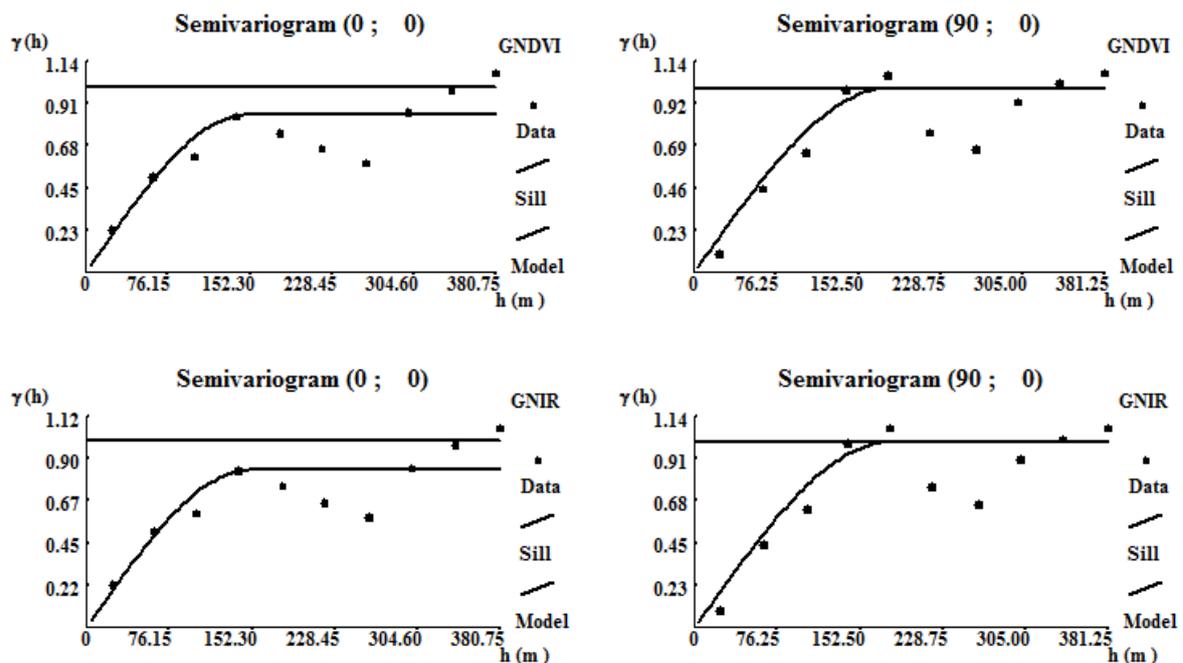


Figura 12. Variogramas dos IVs GNDVI e GNIR para as direções N-S (0°) e E-W (90°).

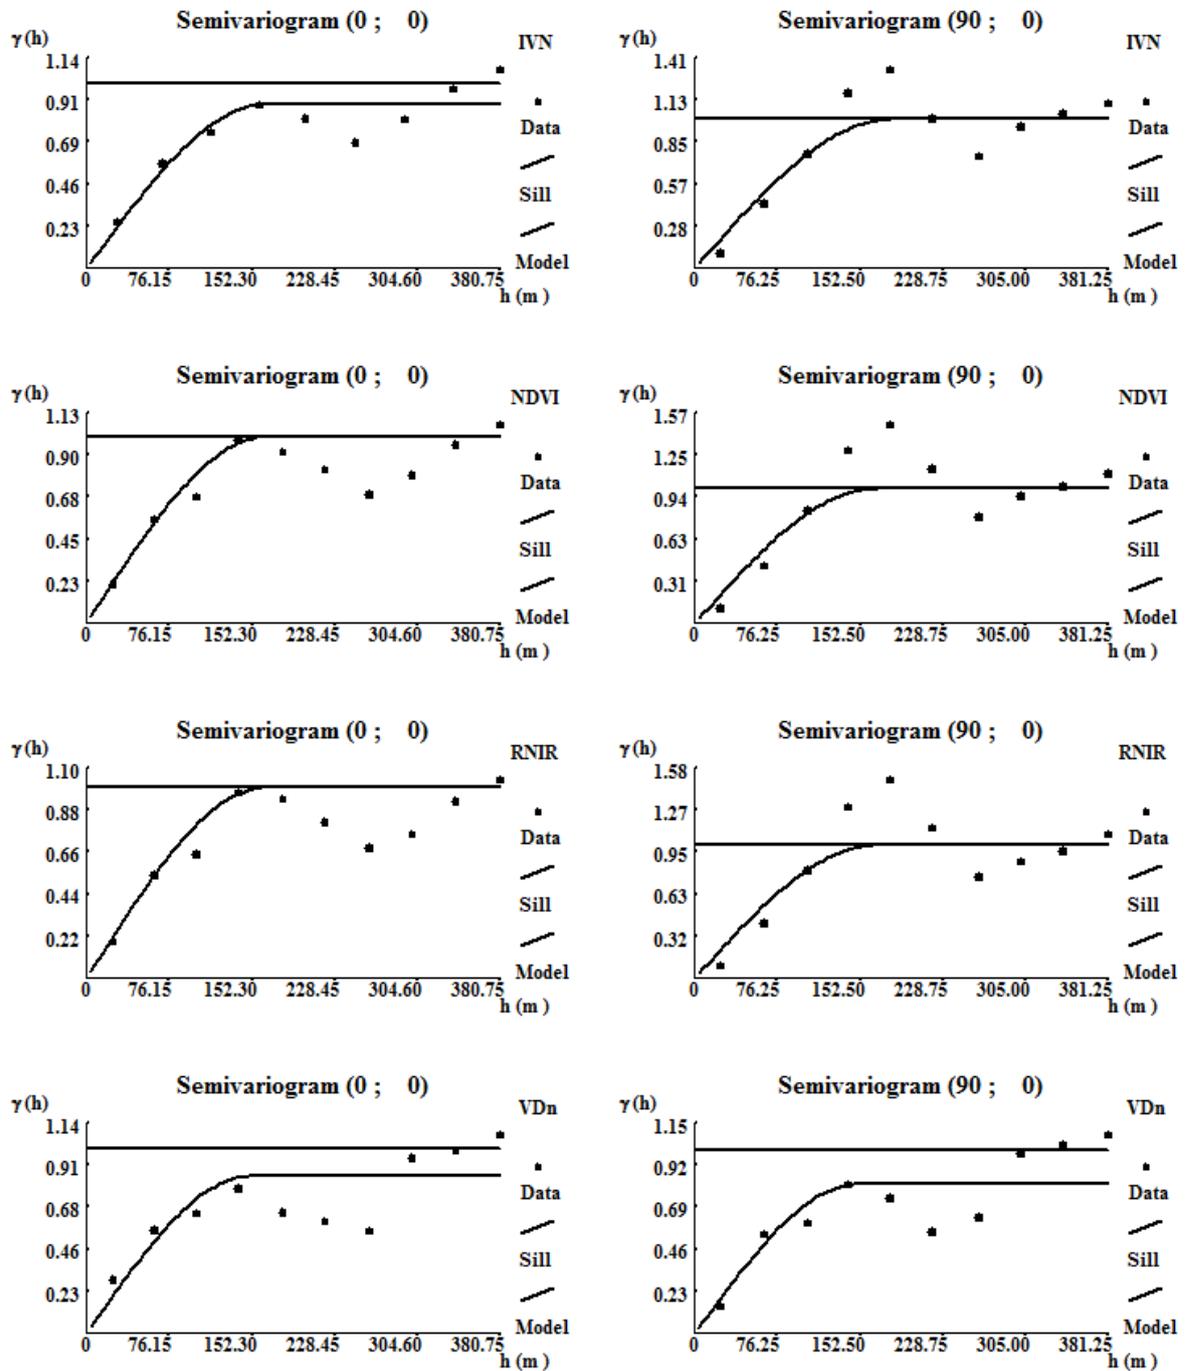


Figura 13. Variogramas dos IVs IV_n, NDVI, RNIR e VD_n para as direções N-S (0°) e E-W (90°).

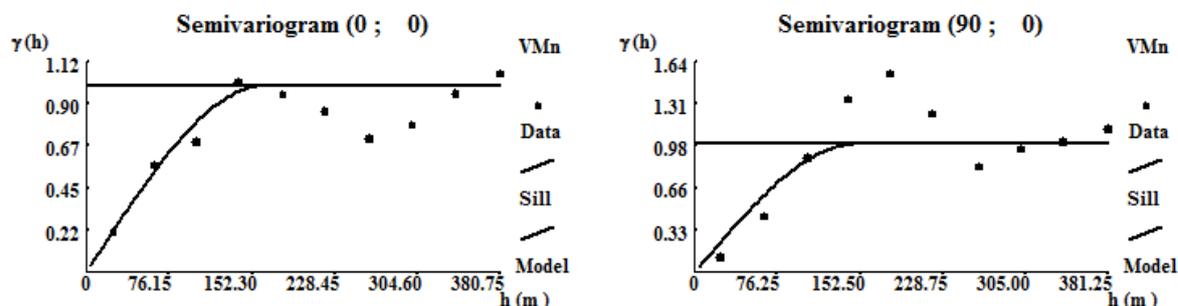


Figura 14. Variogramas do IV VM_n para as direções N-S (0°) e E-W (90°).

Inicialmente, objetivava-se trabalhar com os IVs agrupados, auxiliado por uma estatística multivariada. Entretanto, segundo Lourenço e Landim (2004), para aplicação da análise de regressão multivariada não deve existir relação linear exata ou próxima entre as variáveis independentes. Na Tabela 3 temos a correlação de Pearson entre os diferentes IVs, utilizados como imagens secundárias nas simulações da variável CM.

Tabela 3. Correlação entre os Índices de Vegetação (IVs)

(IV)	GNDV	GNIR	IV_n	NDVI	RNIR	VD_n	VM_n
	I						
GNDVI	-	-0,99	0,98	0,95	-0,95	-0,97	-0,94
GNIR		-	-0,97	-0,95	0,94	0,95	0,92
IV_n			-	0,99	-0,99	-0,87	-0,98
NDVI				-	-0,99	-0,85	-0,99
RNIR					-	0,79	0,99
VD_n						-	0,76
VM_n							-

Na Tabela 3, os índices apresentaram valores de correlação muito semelhantes entre si, implicando num efeito de multicolinearidade, onde todos os índices acabam por exemplificar o mesmo fenômeno, ou ainda, transferir informação semelhante na análise multivariada. Portanto, decidiu-se trabalhar com os índices individualmente, de forma

univariada, tendo entre os objetivos, avaliar qual o IV mais indicado a ser utilizado como imagem secundária nas simulações da variável CM.

6.3 Simulação Sequencial Direta (DSS)

Para que atenda aos pressupostos, as simulações devem apresentar histograma, estatísticas e variogramas semelhantes aos dados amostrais. Na Figura 15 são apresentados o mapa, histograma e variografia da simulação 1, de uma série de 50 simulações da variável CM por DSS.

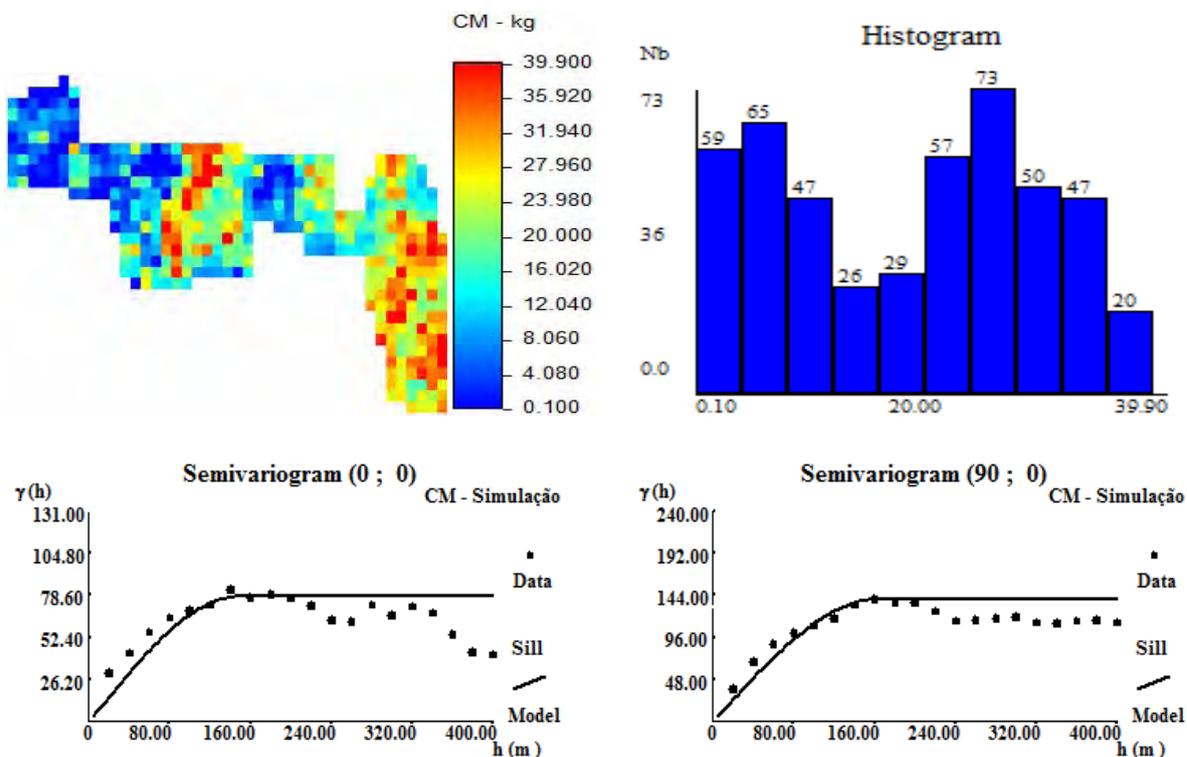


Figura 15. Mapa, histograma e variogramas da simulação 1, de uma série de 50 simulações para a variável CM por DSS.

A Figura 15 apresenta estes parâmetros atendendo perfeitamente aos pressupostos, com distribuição de frequência semelhantes aos dados de campo, conforme

histograma da Figura 8 e variografia com alcance de 150 metros, de acordo com os variogramas da Figura 9.

6.3.1 Incertezas associadas às imagens simuladas pela DSS

A Figura 16 apresenta o mapa da variância das 50 simulações realizadas e o histograma das incertezas associadas à variável CM por DSS.

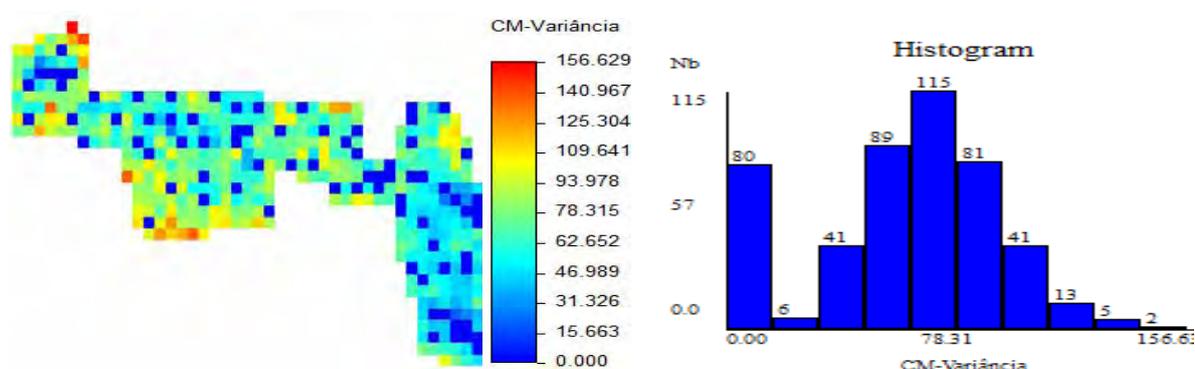


Figura 16. Mapa de variância e histograma das incertezas associadas à variável CM por DSS.

No mapa da Figura 16, os valores de variância 0 (zero) representados pelos pontos em azul escuro, corresponde ao local de amostragem da variável CM. Isso porque, ao longo da realização das simulações pelo método de DSS, os valores reais de campo da variável primária CM são respeitados, por isso a variância nesses pontos é nula. No mapa fica evidente que a insuficiência de pontos amostrados em algumas regiões contribuiu para uma elevação da variância, o que aumenta a incerteza na hora de estimar a variável CM nessas regiões. O histograma do mapa de variância apresentou distribuição sem caldas muito alongadas e com uma coluna de frequência elevada no início da distribuição que representa os valores reais de campo.

6.4 Cosimulação Sequência Direta colocizada com correlação global (CoDSS_CCG)

Na CoDSS_CCG a influência dos dados secundários (IVs) depende da sua correlação global com os dados primários (CM), sendo maior sua influência quanto maior for à correlação. A Tabela 4 apresenta as correlações globais entres os IVs e a variável primária CM.

Tabela 4. Correlação global entre os IVs e a variável primária CM

Veg Index (IV)	Café Maduro (CM)
GNDVI	0,661
GNIR	-0,656
IV _n	0,638
NDVI	0,631
RNIR	-0,626
VD _n	-0,626
VM _n	-0,619

Na Tabela 4 a análise de correlação individual de cada IV com a variável CM, o valor do coeficiente de correlação foi de 0,6 e não variou significativamente entre os índices. Este comportamento pode estar atrelado à transformação das imagens de satélites em índices, que são provenientes de relações entre as mesmas bandas, em sua maioria, para todos os IVs.

Assim como na DSS, cumprindo as exigências para sua realização, foram analisados a distribuição de frequência, por meio dos histogramas e a variografia das imagens simuladas pela CoDSS, que atenderam aos pressupostos exigidos, conforme Figuras 17 a 20.

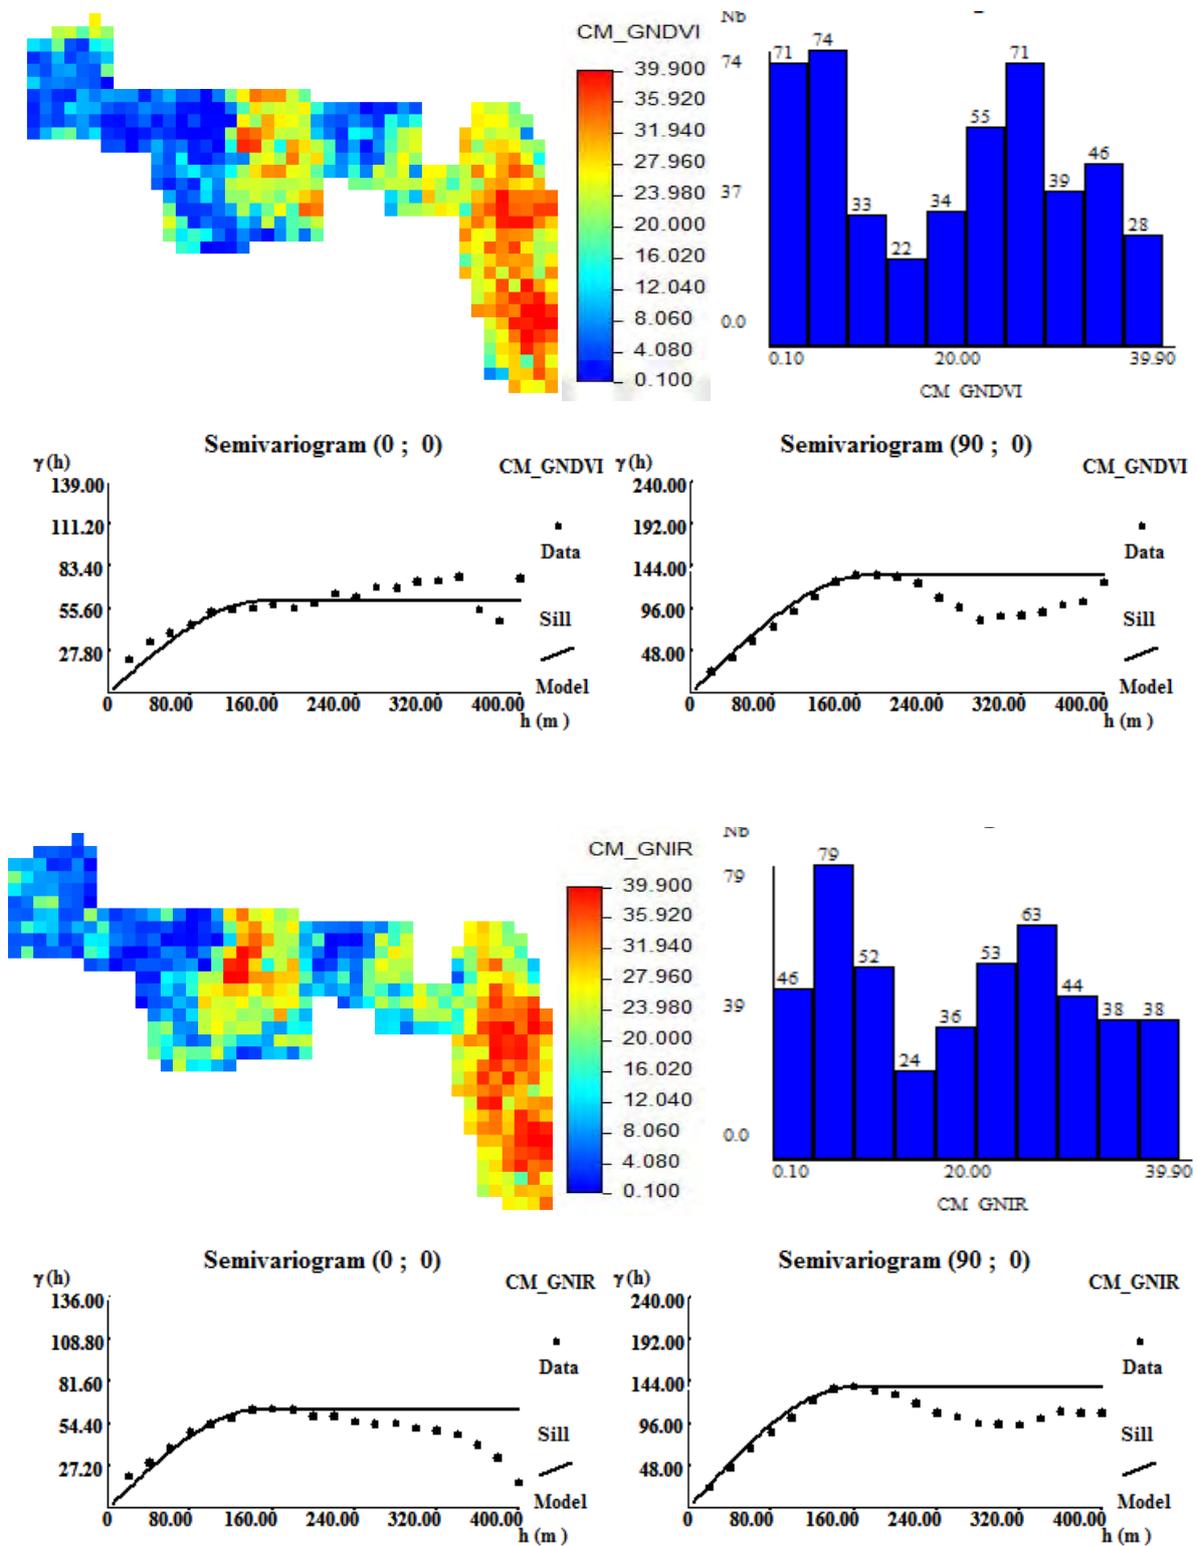


Figura 17. Mapa, histograma e variogramas das cosimulações CM_GNDVI e CM_GNIR.

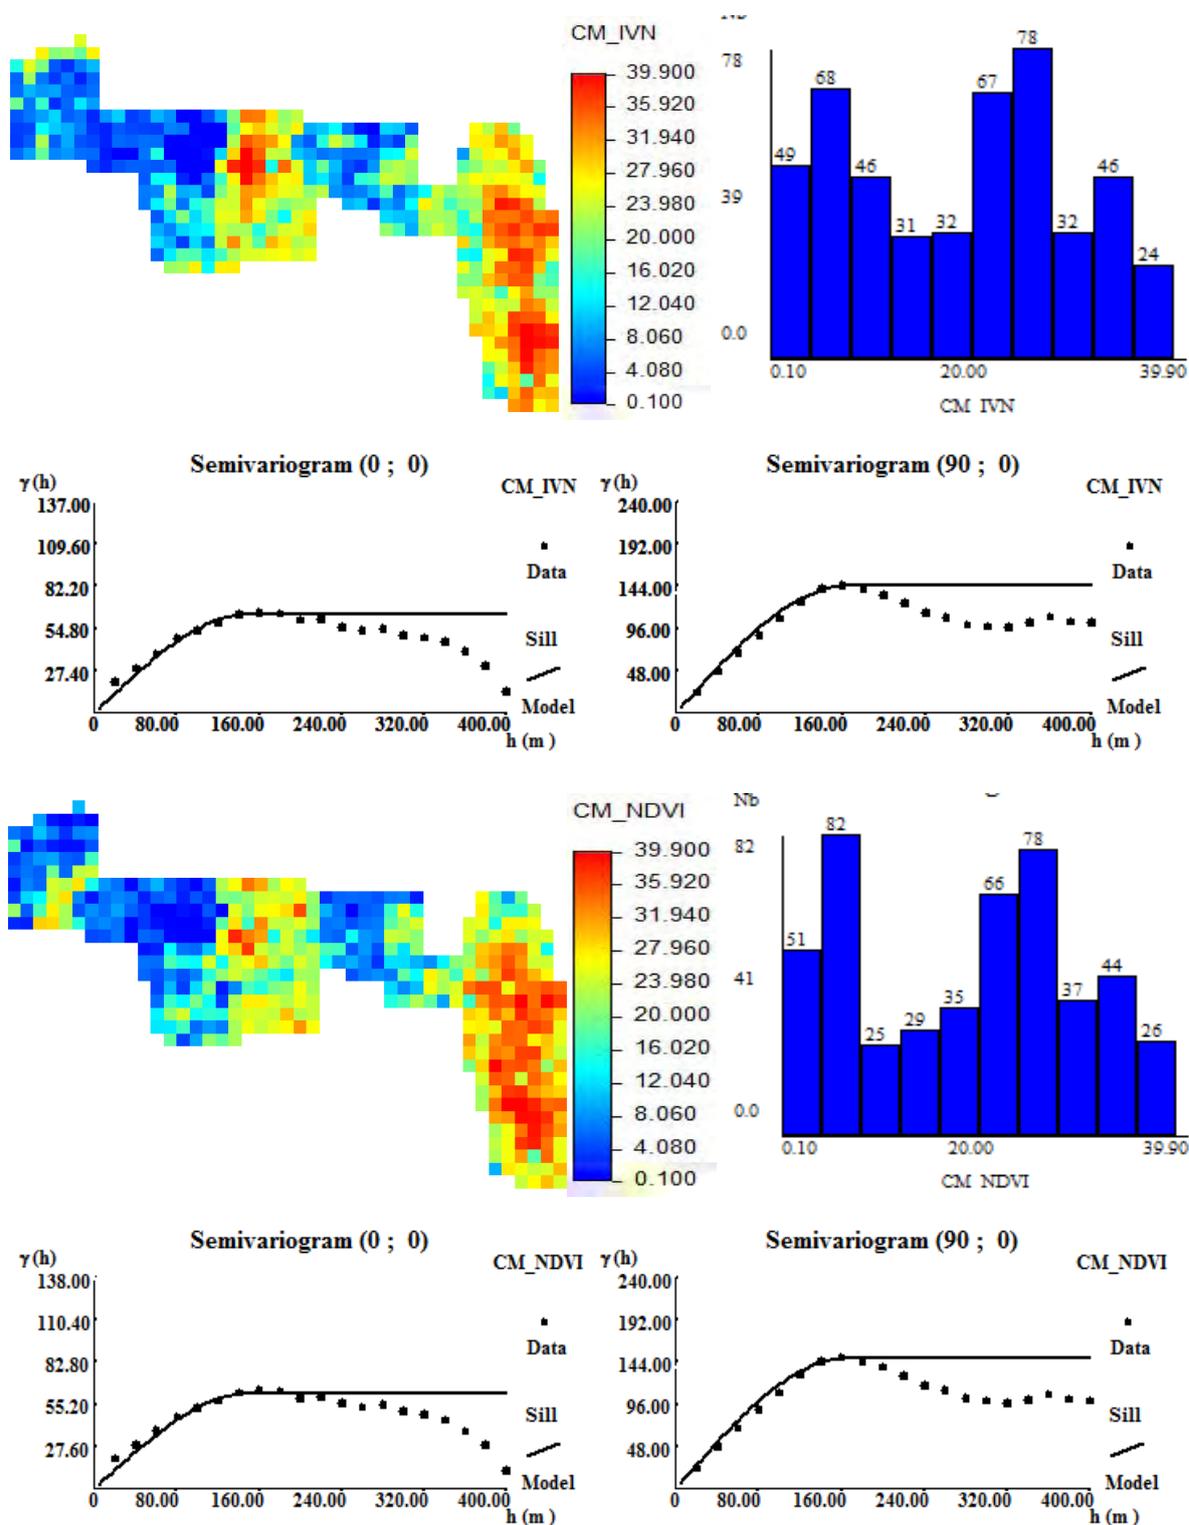


Figura 18. Mapa, histograma e variogramas das cosimulações CM_IV_n e CM_NDVI.

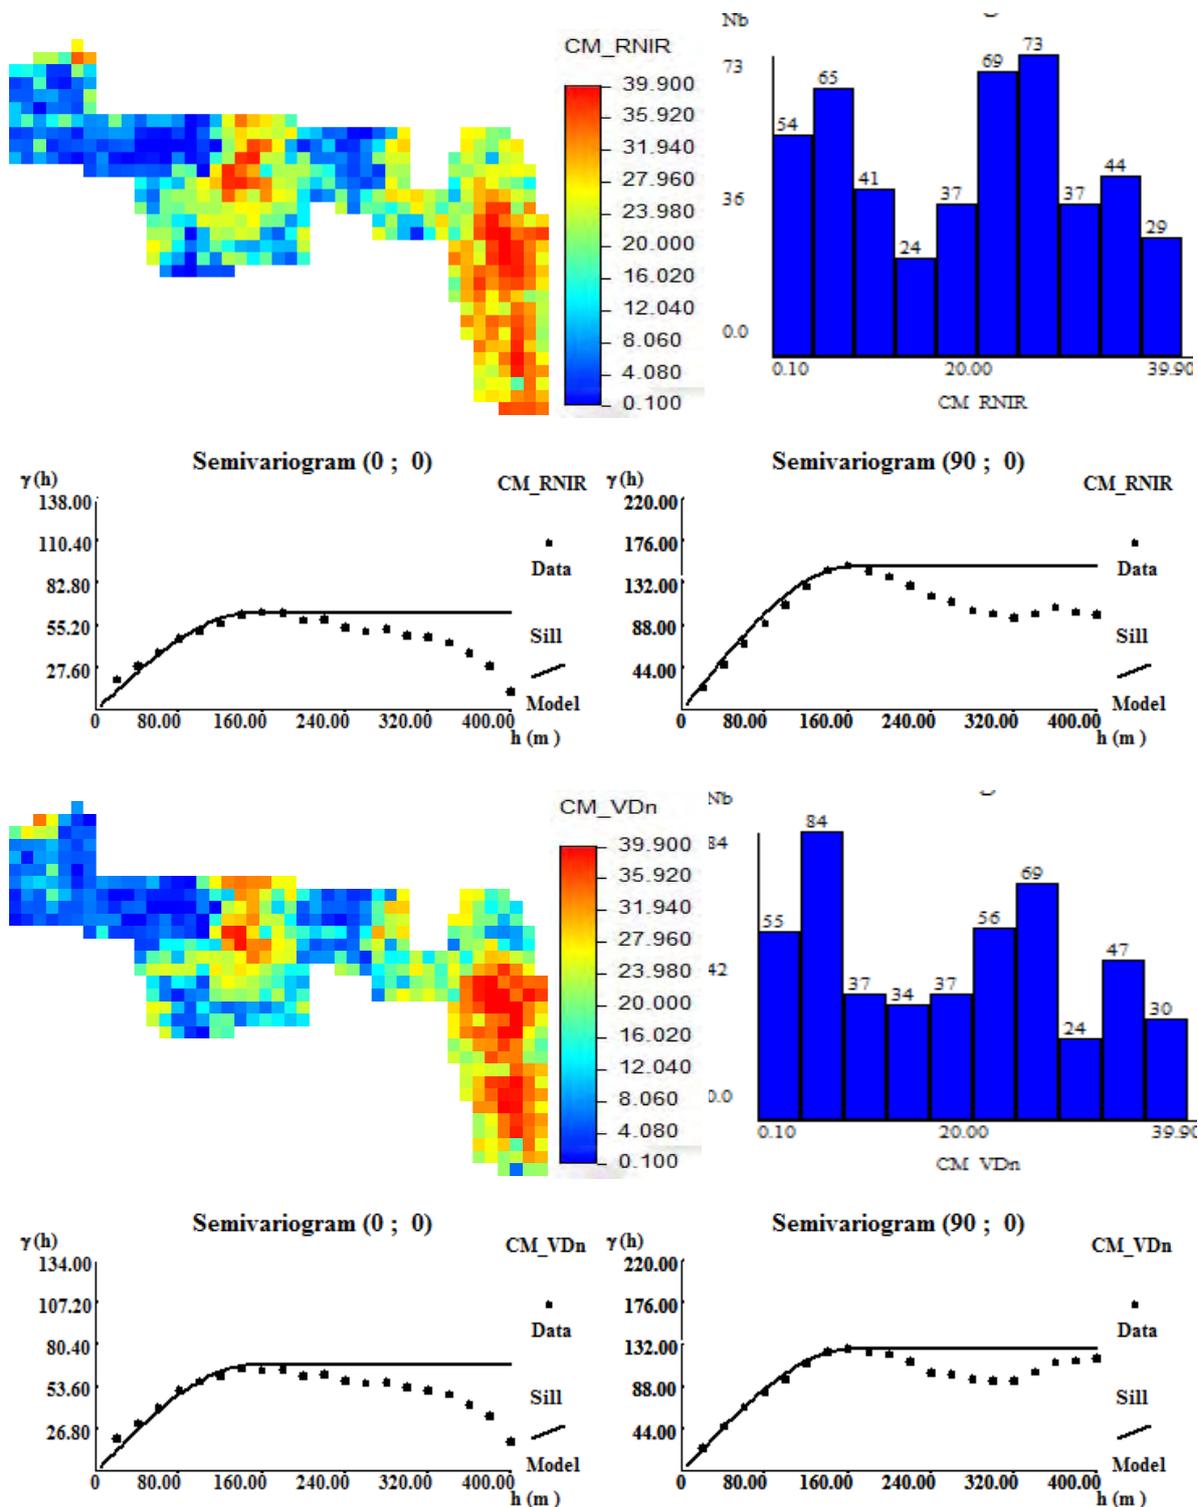


Figura 19. Mapa, histograma e variogramas das cosimulações CM_RNIR e CM_VDn.

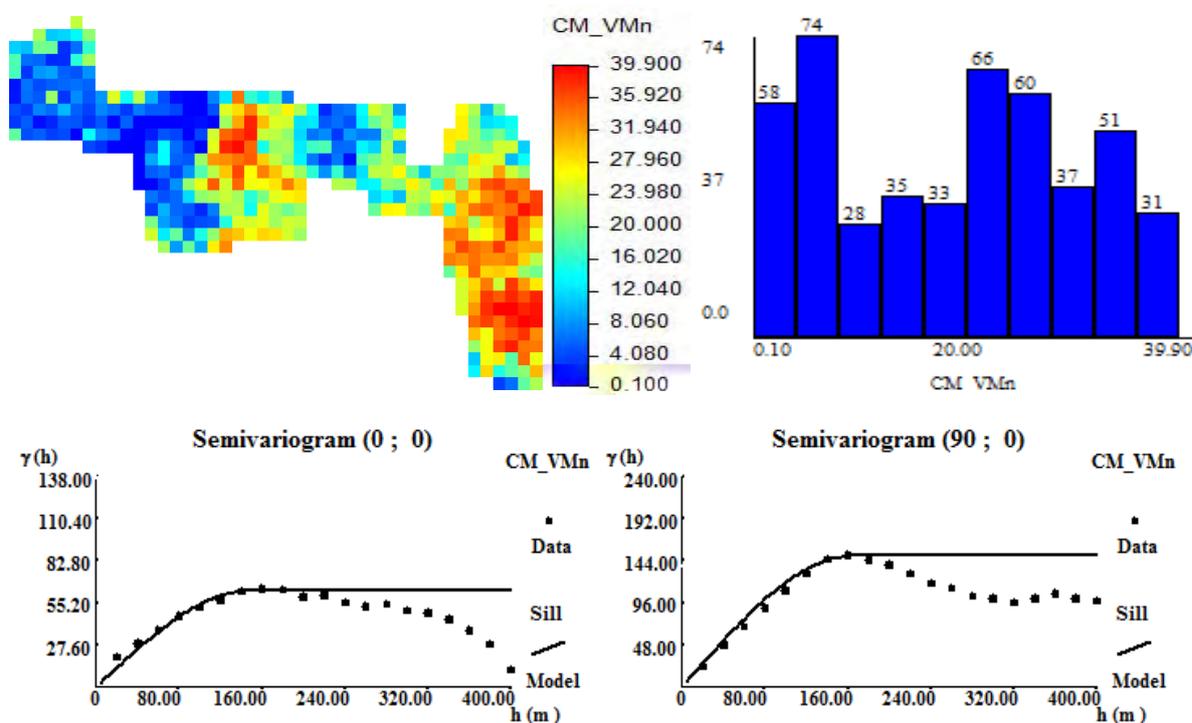


Figura 20. Mapa, histograma e variogramas da cosimulação CM_{VMn} .

6.4.1 Incerteza associada às imagens simuladas pela CoDSS_CCG

Na Figura 21 são apresentados os mapas de variância das 50 simulações feitas pela CoDSS_CCG, utilizados na determinação da incerteza da variável CM. Assim como observado no mapa de variância da DSS (Figura 16), os valores de variância 0 (zero) representados por pontos em azul escuro nos mapas da Figura 21, correspondem aos locais de amostragem da variável CM no campo. A variância possui valor “zero” nesses pontos devido a um dos critérios da CoDSS, de respeitar os dados primários e a sua influência prevalecer sobre os dados secundários na proximidade das observações de campo. Os pontos com maior variância estão presentes nas regiões periféricas dos mapas, com a variância diminuindo à medida que se aproxima dos pontos amostrados. Isso ocorre porque a influência dos dados de campo na estimação da variável CM é máxima quando o ponto a estimar coincide com uma observação de campo e vai diminuindo com o aumento da distância.

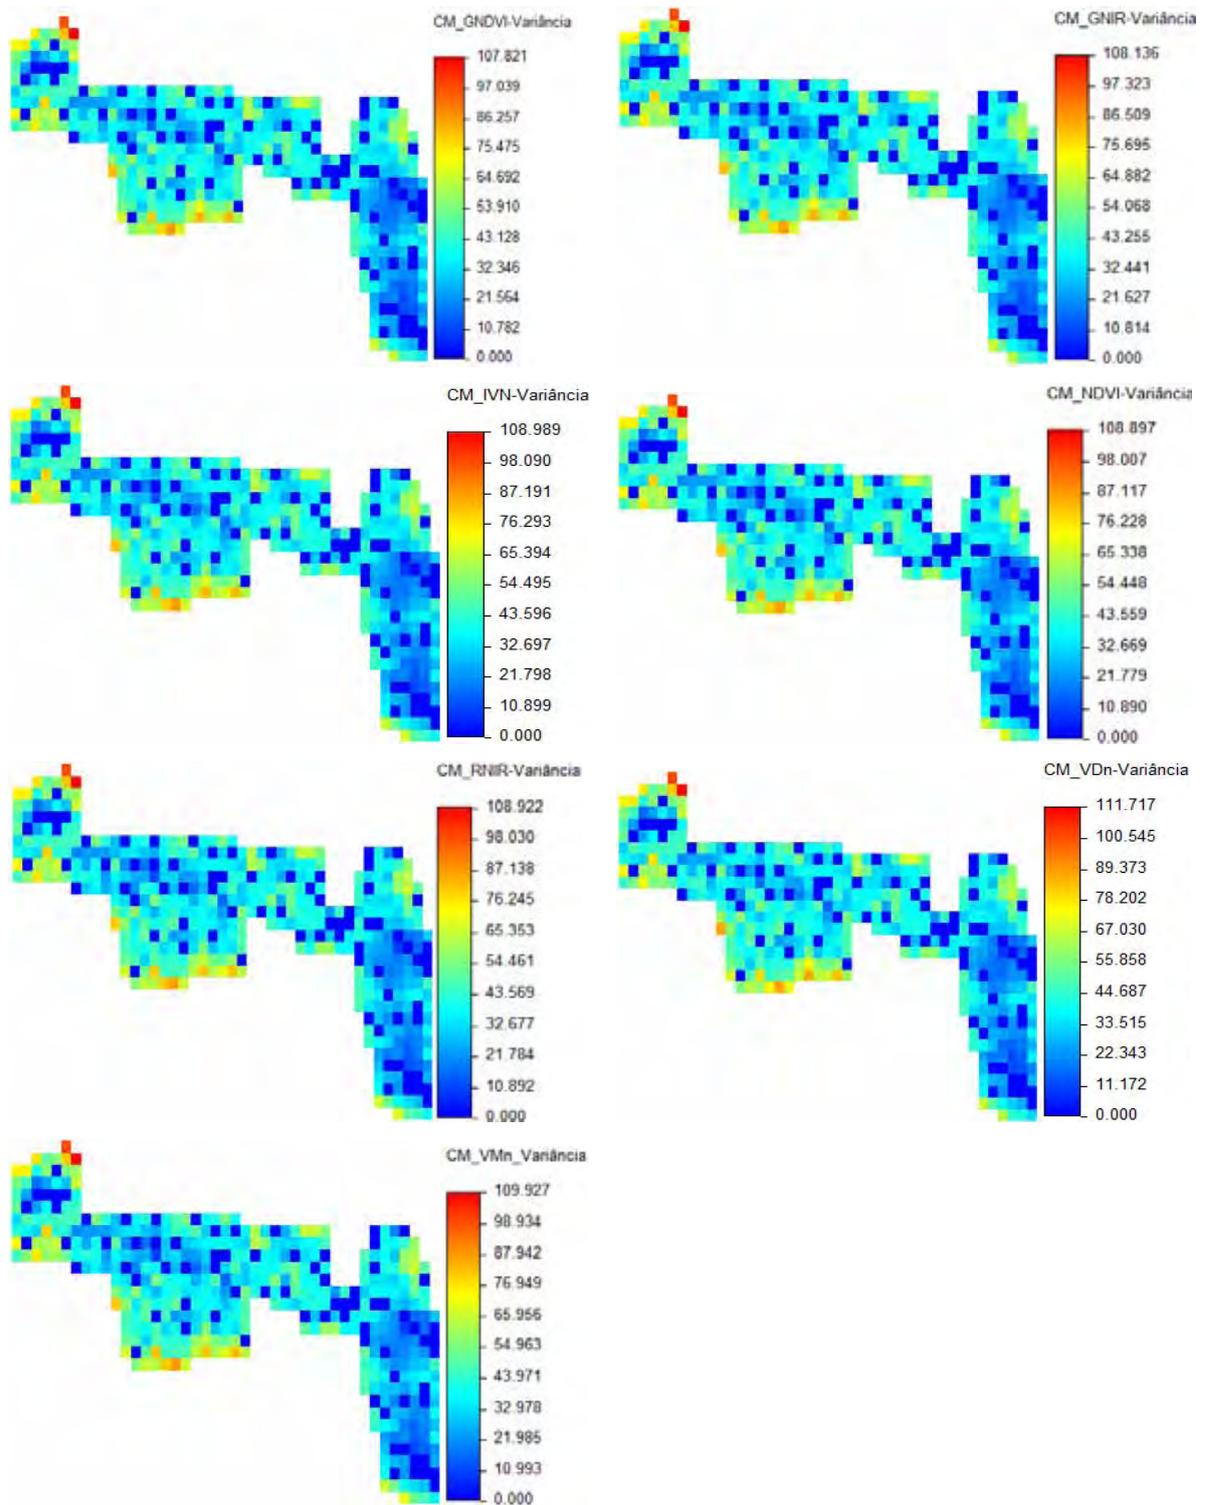


Figura 21. Mapas das variâncias das imagens simuladas da variável CM por CoDSS_CCG.

Dentre os IVs não ocorreram diferenças visuais significativas quanto à distribuição da incerteza na área. A Figura 22 apresenta os histogramas dos mapas de variâncias da Figura 21.

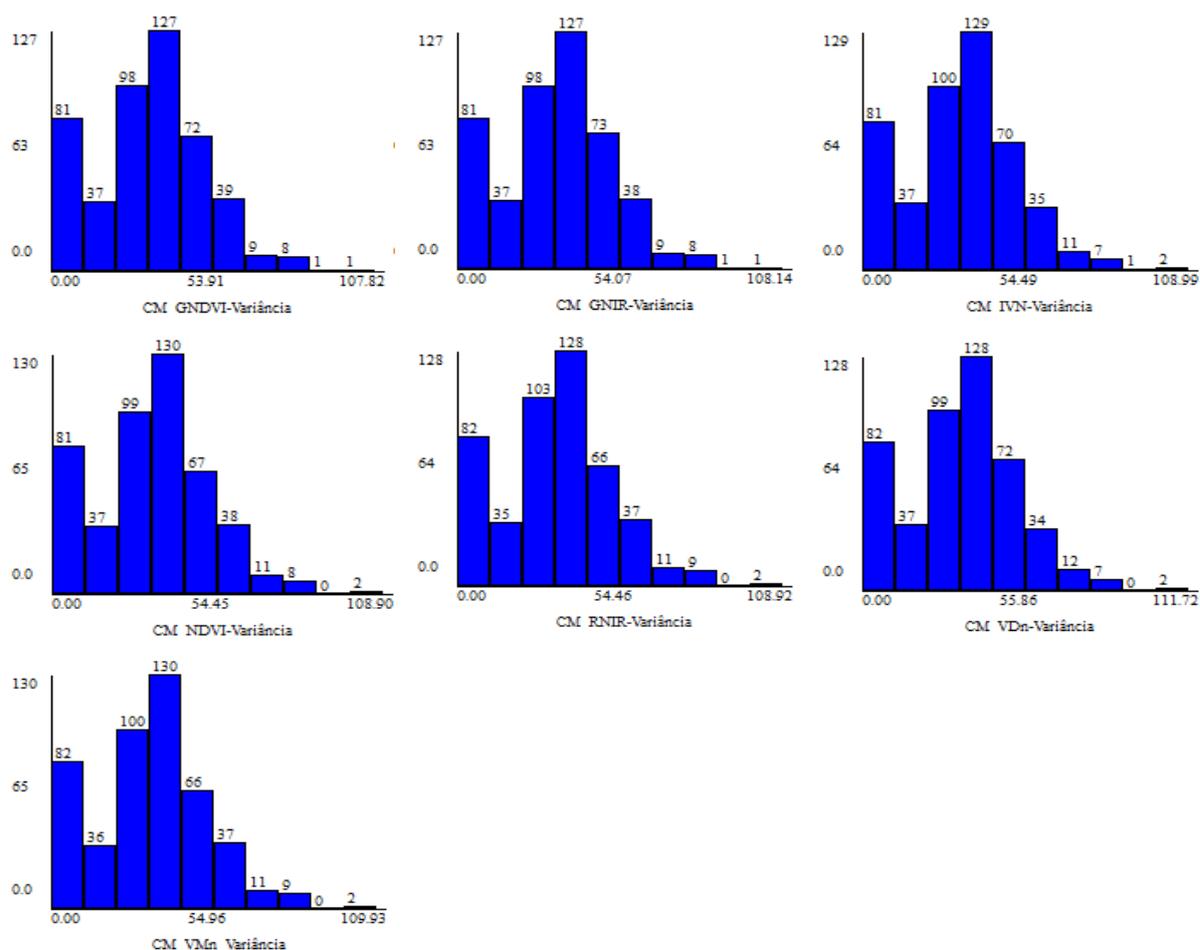


Figura 22. Histograma das incertezas associadas aos mapas simulados por CoDSS_CCG.

Assim, como observados nos mapas, os histogramas demonstraram aparentemente a mesma distribuição de frequência da variância para todos os IVs utilizados. Comportamento este, ainda mais evidenciado, pelos valores do Coeficiente de assimetria (C_s) que não apresentou oscilações significativas, variando 0,06 a 0,08 entre os IVs. Comparando as distribuições da Figura 22 com o histograma da variância da DSS (Figura 16) nota-se grande diferença na distribuição das incertezas, com a CoDSS_CCG apresentando uma ligeira

assimetria positiva, mostrando uma maior concentração da variância abaixo da média, indicando menor valor de incerteza associado a variável CM na área.

Para os IVs utilizados como imagens secundárias, a correlação global variou de 61,9 a 66,1 (Tabela 4), sendo a maior correlação para o índice GNDVI e a menor para o VM_n. Portanto, decidiu-se testar a CoDSS_CCL para identificação de regiões na área com maiores correlações e possíveis diferenças entre os IVs, com a identificação de correlações locais.

6.5 Cosimulação Sequência Direta colocalizada com correlação local (CoDSS_CCL)

Na CoDSS_CCL, a influência da variável secundária na primária é feita por blocos (janelas), com as correlações podendo variar ao longo da área, em função do tamanho destes blocos ou “janelas móveis” como são chamadas.

6.5.1 Mapas de correlações locais

No caso em estudo, foram testados vários raios de busca para o cálculo das correlações locais entre os 87 pontos amostrais (dados primários) e os correspondentes dados secundários. Ao final dos testes, foi utilizada uma janela móvel de 60 metros (aproximadamente metade da continuidade espacial da variável CM), por ser considerado o raio mais apropriado tendo em conta o número de observações vizinhas envolvidas e a variabilidade espacial da correlação nos dados, conforme Carvalho (2002). Com base na krigagem as correlações locais foram interpoladas para toda a área de estudo de forma a se obter as superfícies de correlação para cada um dos IVs usados como imagens secundárias. A Figura 23 apresenta os mapas estimados por krigagem das correlações locais entre a variável CM e cada IV.

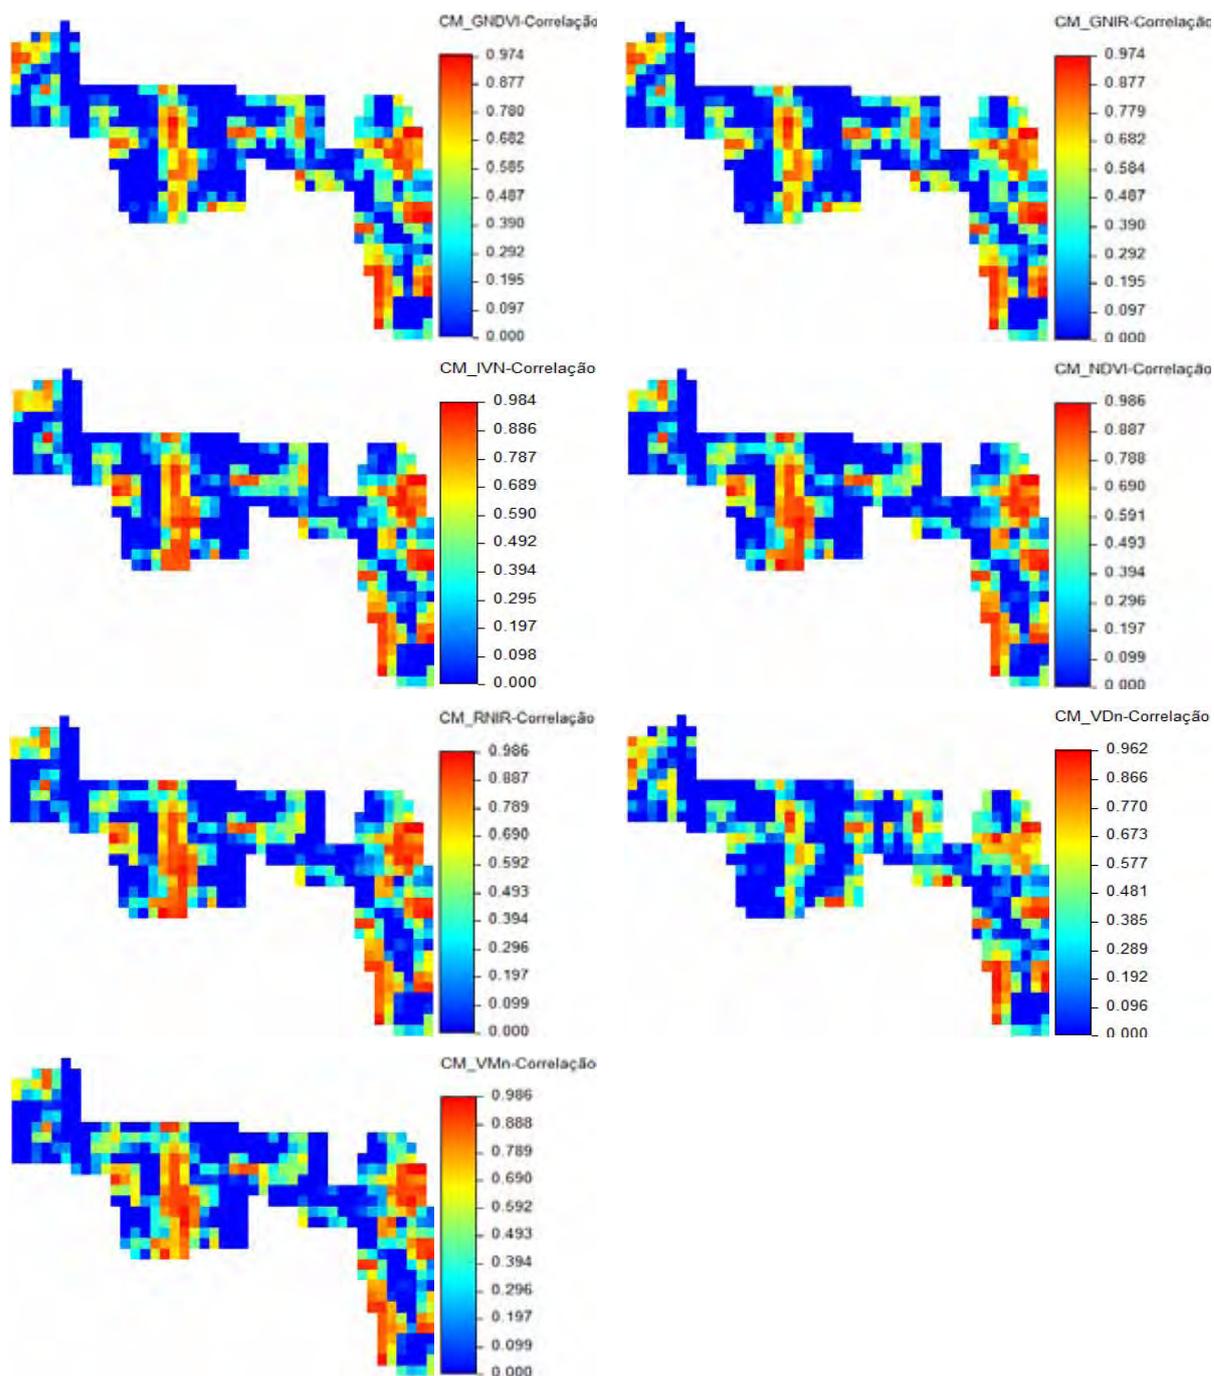


Figura 23. Mapas das correlações locais estimados por krigagem.

Pela análise da distribuição espacial das correlações locais, verifica-se a segmentação da área de estudo em zonas de baixa, média e altas correlações, que não

aparentam seguir uma direção de continuidade preferencial, tal como para os dados primários e secundários, optando-se por construir variogramas experimentais omnidirecionais. Os mapas da Figura 23 correspondem ainda, a imagens construídas com base em valores interpolados, originando, portanto, imagens atenuadas dos valores da variável em estudo, já que os novos valores interpolados resultam de uma combinação linear das observações envolventes, ou seja, de uma média ponderada desses valores.

Assim como na DSS e CoDSS_CCG, os pressupostos exigidos para realização das simulações na CoDSS_CCL foram atendidos, com a distribuição de frequência e variográfica das simulações semelhante aos dados amostrais.

6.5.2 Incerteza associada às imagens simuladas pela CoDSS_CCL

A Figura 24 apresenta os mapas de variância das 50 simulações feita pela CoDSS_CCL para os IVs utilizado na determinação da incerteza da variável primária CM. Assim como na CoDSS_CCG, os mapas de variância, mostraram que o uso dos IVs como dados secundários na CoDSS_CCL, diminuiu a variância das simulações, logo, as áreas de incerteza, principalmente nos locais afastados dos pontos de amostragem da variável CM na área. Diferente do comportamento encontrado na CoDSS_CCG, com as correlações locais, ocorreram pequenas variações na distribuição de frequência da variância, entre os IVs, devido o aumento da gama de valores de correlação em algumas áreas para cada IV.

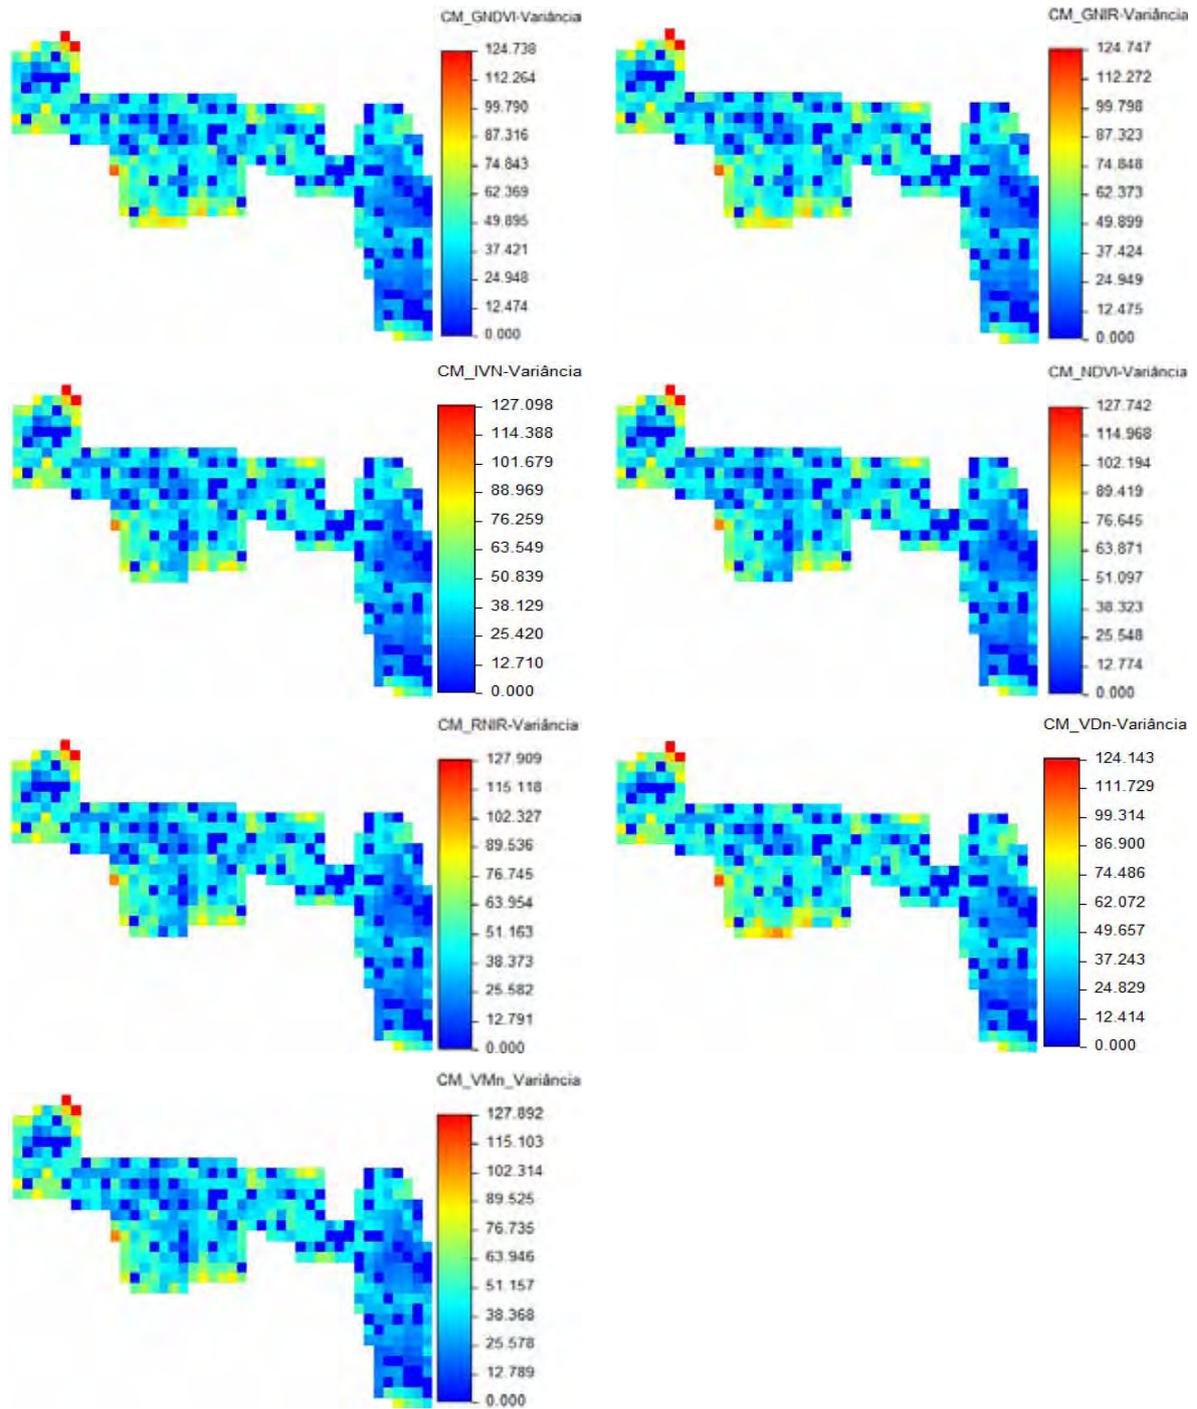


Figura 24. Mapas de variância das imagens simuladas da variável CM por CoDSS_CCL.

Essas pequenas oscilações entre os IVs foram detectadas também pelos histogramas dos mapas de variâncias, apresentados na Figura 25.

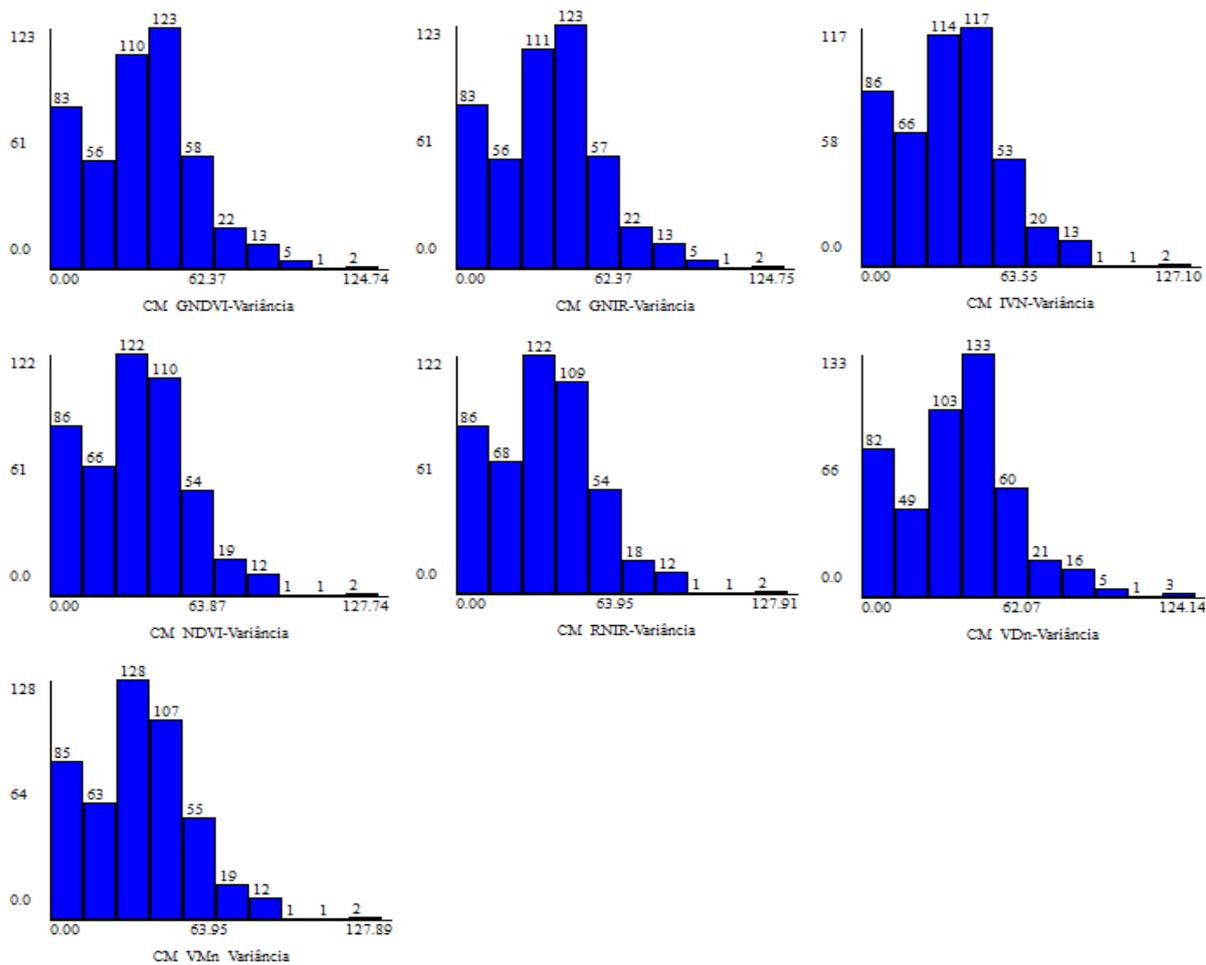


Figura 25. Histograma das incertezas associadas aos mapas simulados por CoDSS _CCL.

Os histogramas da Figura 25 apresentaram maior concentração dos valores da variância abaixo da média, que nos histogramas da DSS e CoDSS_CCG. Além de visual a diferença nos histogramas entre os métodos de simulação foi evidenciada por algumas estatísticas.

6.6 Análise da incerteza dos métodos de simulação

Na Tabela 5 são apresentados os coeficientes de Assimetria (C_s) da distribuição de frequência dos mapas de variâncias gerados pelos 3 métodos de simulação. Primeiramente, observa-se a grande vantagem em utilizar os IVs como imagens preditoras na determinação das incertezas associadas a variável CM, por meio das técnicas de CoDSS. Tanto na CoDSS_CCG como na CoDSS_CCL, os valores do C_s , para todos os IVs, foram positivos (0,076 e 0,36 em média, respectivamente), enquanto que a DSS apresentou uma assimetria negativa (-0,41), evidenciando assim uma maior incerteza ligada as imagens simuladas da variável CM por esse método.

Tabela 5. Valores do Coeficiente de assimetria dos mapas de variância para DSS e CODSS com correlação global e local

IMAGEM	C_s ¹		
	DSS	CoDSS_CCG	CoDSS_CCL
CM_GNDVI		0,06	0,33
CM_GNIR		0,07	0,33
CM_IV _n		0,08	0,38
CM_NDVI		0,08	0,40
CM_RNIR		0,08	0,40
CM_VD _n		0,08	0,30
CM_VM _n		0,08	0,38
MEDIA	-0,41	0,076	0,36

¹ Coeficiente de assimetria

Dentre os métodos de CoDSS, a correlação local apresentou maior valor positivo de C_s , logo, possível menor incerteza associada. E ainda, enquanto na CoDSS_CCG não se observou diferenças quanto às incertezas entre os IVs, nas Figuras 24 e 25, observamos diferenças visuais nos mapas de variância e na distribuição de frequência, respectivamente, entre os histogramas dos IVs. Além disso, algumas estatísticas comprovam este fato, como é o caso do C_s . Na CoDSS_CCG o C_s entre os IVs foram iguais, com as

imagens apresentando uma distribuição simétrica e os valores de assimetria próximos de 0 (zero). Enquanto na CoDSS_CCL o C_s variou entre 0,3 e 0,4 entre os IVs, com menor assimetria para a imagem CM_VD_n (0,30) e maior assimetria positiva para as imagens CM_NDVI e CM_RNIR (0,40), sendo portanto estas últimas às imagens com menor valor de incerteza associada às simulações pela análise do C_s .

Porém, na CoDSS_CCL, a média das variâncias foi superior a da CoDSS_CCG, para todos os IVs, com o valor máximo de variância entre os IVs variando de 124,1 a 127,9 para a correlação local e 107,8 a 111,71 para a global. Com isso, a análise das incertezas das observações na área pelo C_s não foi suficiente para determinar qual o melhor IV e método de simulação para a predição da variável CM.

6.7 Quantificação da incerteza

Para a quantificação da incerteza associada a variável primária CM, estabeleceu um limite de corte fixo para a variância igual a 80, sendo este valor baseado no Perc₉₅ médio entre as variâncias da DSS, CoDSS_CCG e CoDSS_CCL.

Na Figura 26 são apresentados os mapas quantificados das incertezas associada a variável primária CM pela DSS e CoDSS_CCG, para todos os IVs utilizados, respectivamente.

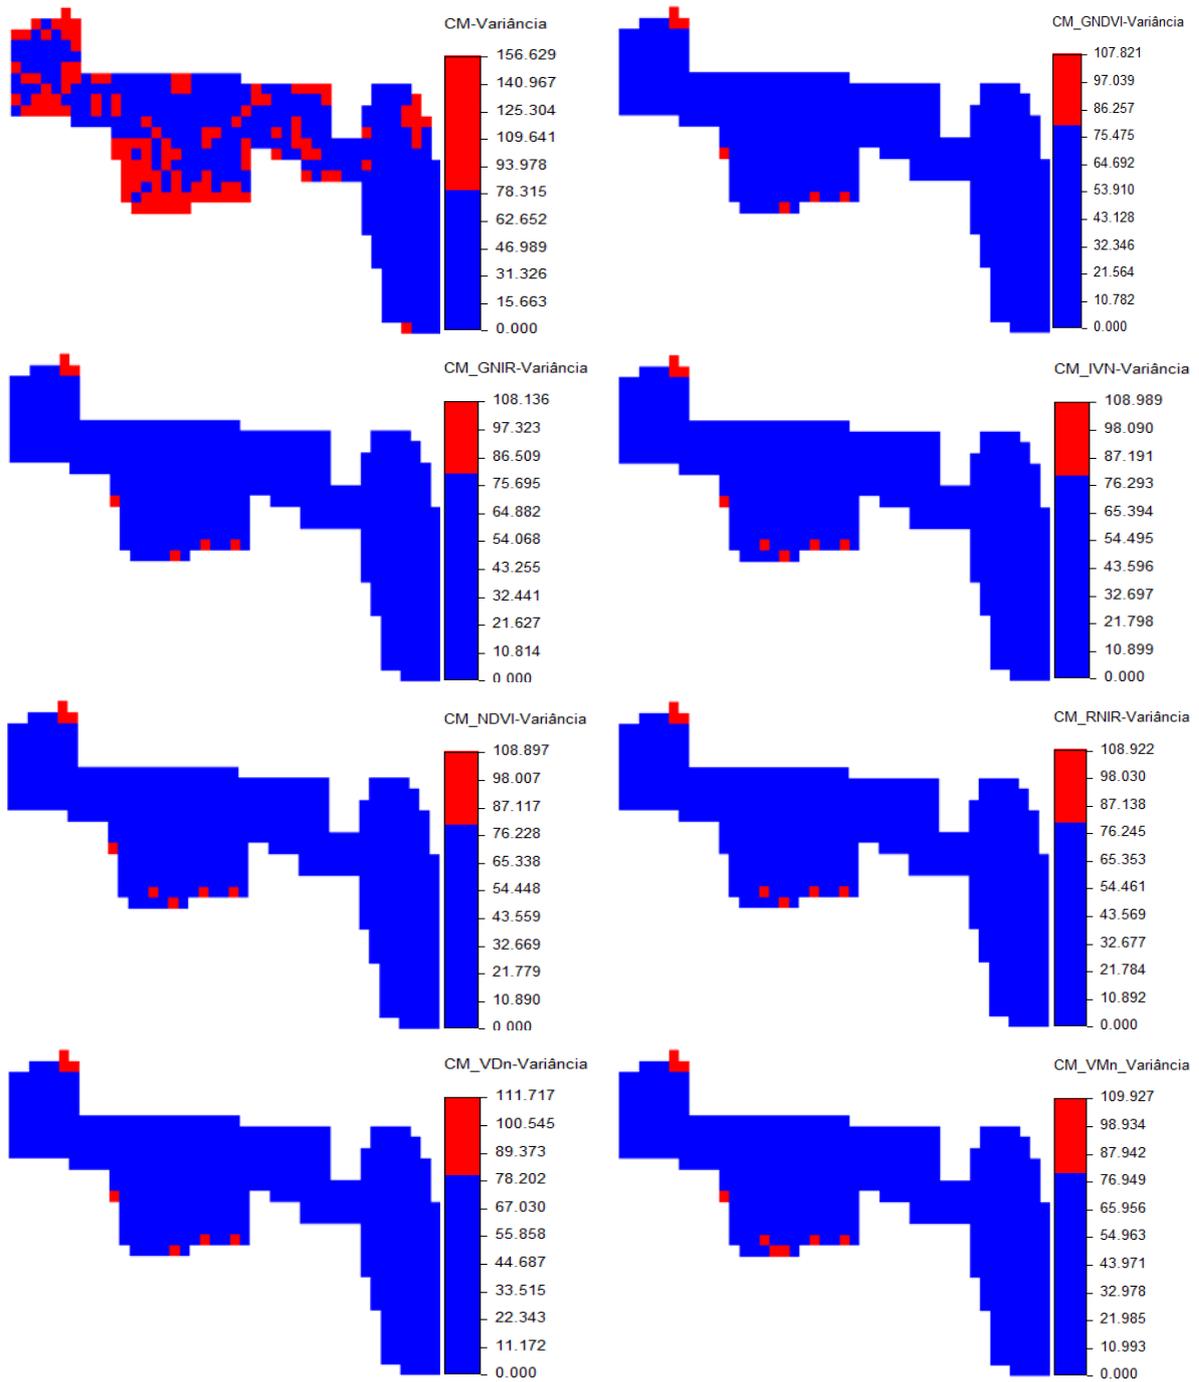


Figura 26. Mapas de quantificação da incerteza associada a variável CM pela DSS e CoDSS_CCG com limite de corte baseado no valor médio do Perc₉₅, para cada IV, respectivamente.

Na Figura 27 são apresentados os mapas quantificados das incertezas associada a variável primária CM pela CoDSS_CCL para todos os IVs utilizados.

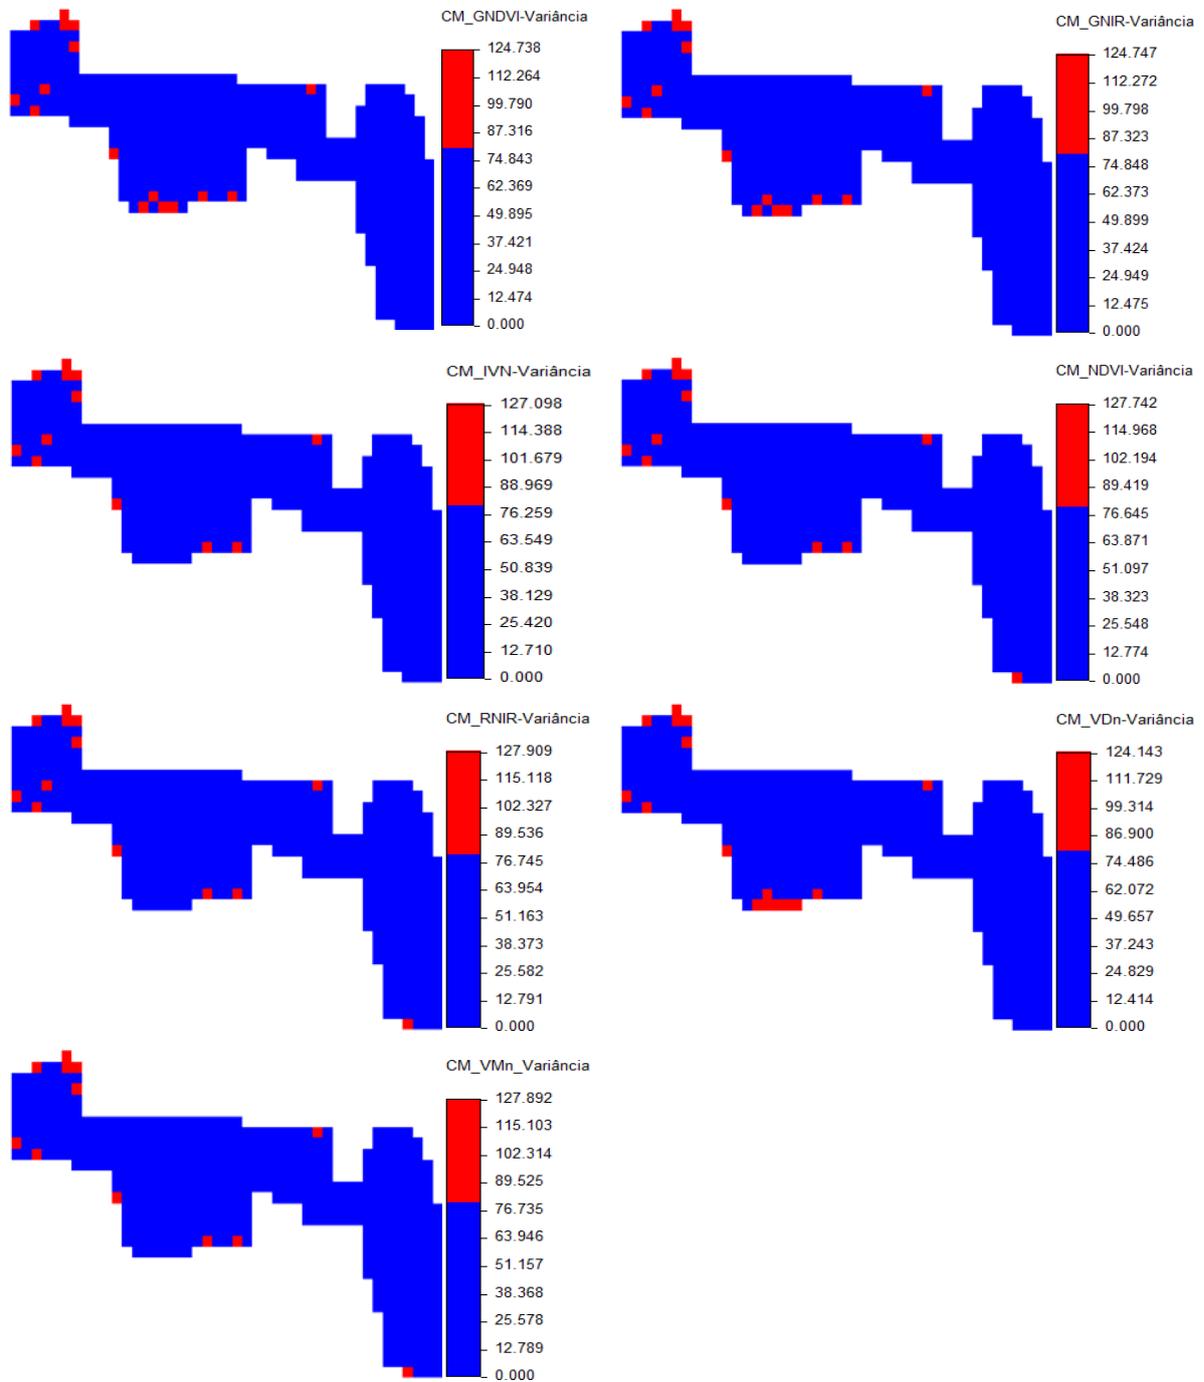


Figura 27. Mapas de quantificação da incerteza associada a variável CM pela CoDSS_CCL com limite de corte baseado no valor médio do Perc₉₅, para cada IV.

Os Pixels em vermelho nos mapas das Figuras 26 e 27 representam pontos de incerteza, baseado no valor de corte 80 da variância. Esses pixels indicam regiões no mapa onde a amostragem dos pontos da variável primária foi ineficiente para uma estimativa mais precisa da variável no campo e, portanto, uma nova amostragem mais representativa da variável nessas áreas deveria ser feita. O primeiro mapa da Figura 26 que corresponde às incertezas quantificadas para a DSS, apresentou grande parte da área classificada como incerta para estimativas da variável CM. Enquanto o restante dos mapas da Figura 26 e os mapas da Figura 27, que representam as incertezas quantificadas pela CoDSS, apresentaram algumas unidades apenas de pontos localizados nas extremidades da área, evidenciando a eficiência do uso das imagens secundárias.

A Tabela 6 apresenta as áreas de incertezas dos mapas das Figuras 26 e 27, quantificadas por ha e %. Inicialmente o que se observa é a eficiência da utilização dos IVs como imagens secundárias, ou ainda, da CoDSS colocada na determinação da incerteza para melhor estimar a variável CM. Com a DSS apresentando 26,43 % (5 ha) de incerteza na área total, enquanto a CoDSS_CCG variou de 1,48 a 1,90 % (0,28 a 0,36 ha) e a CoDSS_CCL variando de 2,54 a 3,38 % (0,48 a 0,64 ha) de incerteza, de acordo com os IVs. Na CoDSS_CCG as imagens CM_GNDVI, CM_GNIR, CM_RNIR e CM_VD_n, apresentaram a menor área de incerteza (1,48 %), sendo assim, estes, os melhores IVs a serem utilizados como imagens secundárias. Enquanto na CoDSS_CCL, os melhores resultados foram encontrados para os IVs IV_n e VM_n (2,54 %). Porém comparando os IVs em cada CoDSS, observa-se que a diferença entre os valores de área (ha) de incerteza são muito próximos e sem grande significância, variando de 0,28 a 0,36 ha para a Global e 0,48 a 0,64 ha para a, Local.

Tabela 6. Quantificação por área (ha e %) da incerteza associada à variável CM pela DSS e para cada imagem secundária (IV) nos 2 casos de cosimulações testados

DSS			
IMAGEM	BLOCOS	ÁREA	
		(ha)	(%)
CM	125	5	26,43
CoDSS_CCG			
IMAGEM	BLOCOS	ÁREA	
		(ha)	(%)
CM_GNDVI	7	0,28	1,48*
CM_GNIR	7	0,28	1,48*
CM_IV _n	8	0,32	1,69
CM_NDVI	8	0,32	1,69
CM_RNIR	7	0,28	1,48*
CM_VD _n	7	0,28	1,48*
CM_VM _n	9	0,36	1,90
CoDSS_CCL			
IMAGEM	BLOCOS	ÁREA	
		(ha)	(%)
CM_GNDVI	16	0,64	3,38
CM_GNIR	16	0,64	3,38
CM_IV _n	12	0,48	2,54*
CM_NDVI	13	0,52	2,75
CM_RNIR	13	0,52	2,75
CM_VD _n	16	0,64	3,38
CM_VM _n	12	0,48	2,54*

* Menor área de incerteza

Uma diferença maior é observada entre os tipos de CoDSS, e, ao contrário do observado nos histogramas e coeficiente de assimetria das variâncias, a Tabela 6 evidencia que a CoDSS_CCG apresentou menor área de incerteza associada à variável CM para todos os IVs utilizados, quando comparada com a CoDSS_CCL. Este comportamento é explicado quando analisamos os gráficos de correlação da variável CM com cada IV, apresentados na Figura 28.

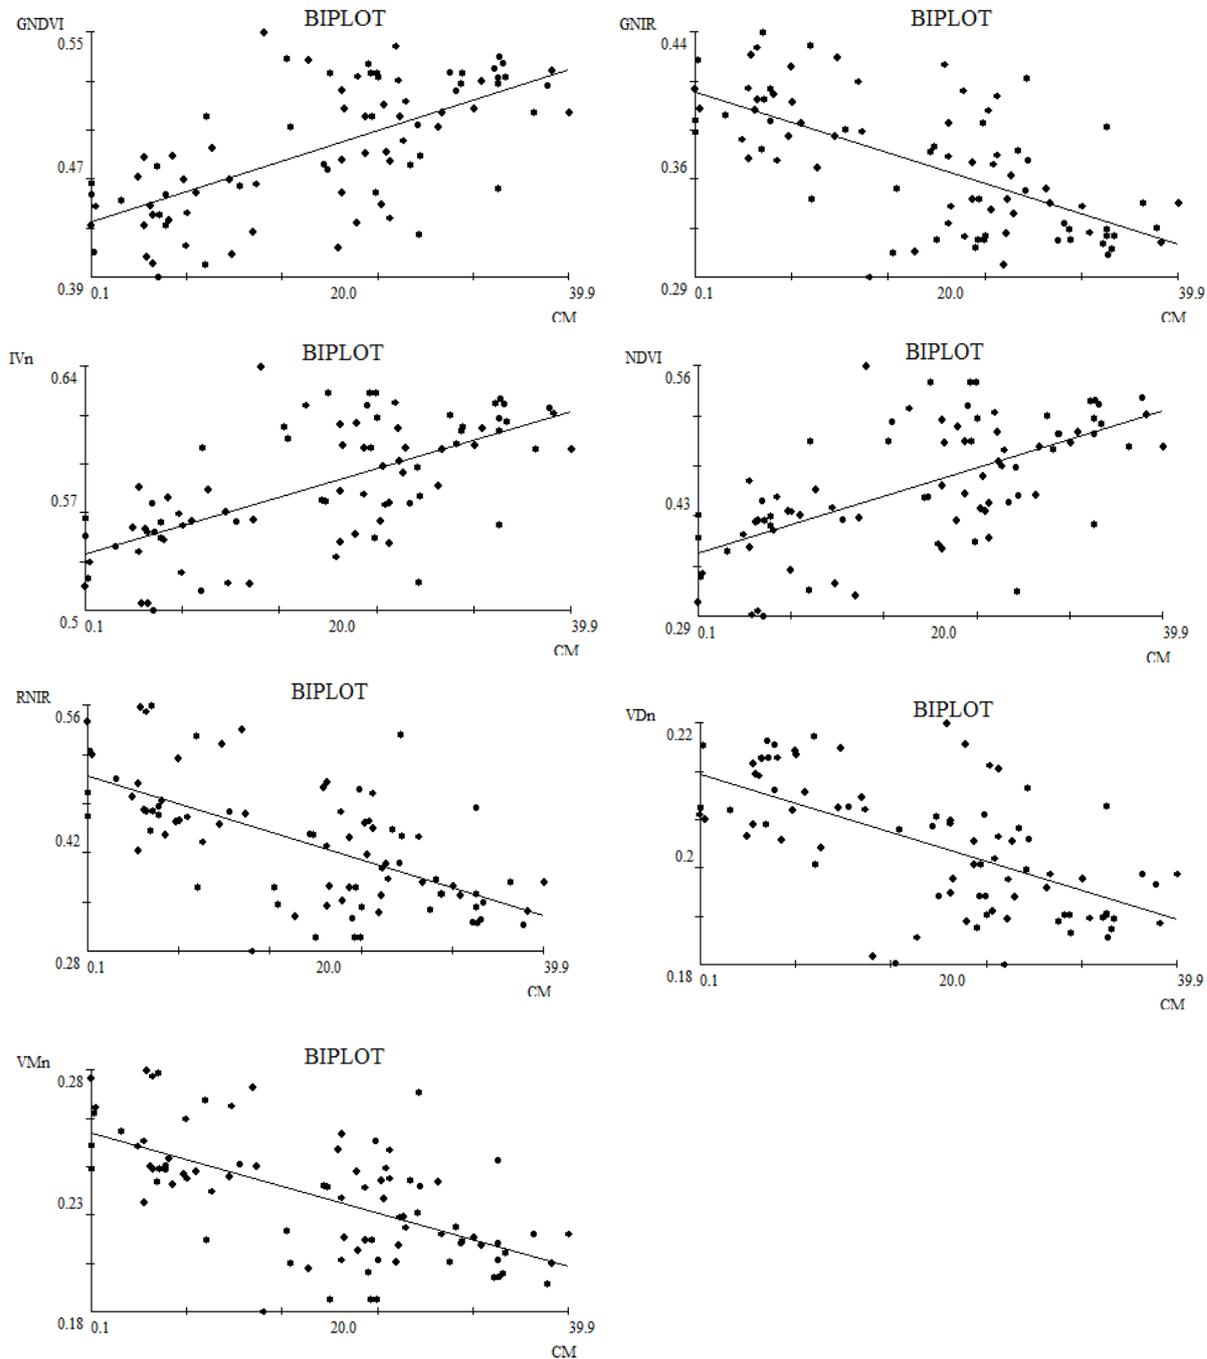


Figura 28. Gráficos de correlação entre a variável CM e os IVs.

Os gráficos de correlação apresentados na Figura 28, mostram um grande espalhamento das amostras ao longo do modelo teórico, com a fácil distinção de dois grandes grupos de pontos ao longo da reta. Isso mostra que uma correlação entre a variável

CM e os IVs, só é possível de forma global. Impossibilitando, assim, ou ainda, diminuindo esta relação em regiões específicas da áreas, como por exemplo no caso da utilização de “janelas móveis” para determinação de correlações locais.

Na Figura 29 temos o gráfico de correlação GNDVI_CM dividido em dois, utilizando o valor 14 kg da variável CM como limite de corte, que define os dois grupos de pontos, para explicar visualmente a menor eficiência das “janelas móveis” neste caso de estudo.

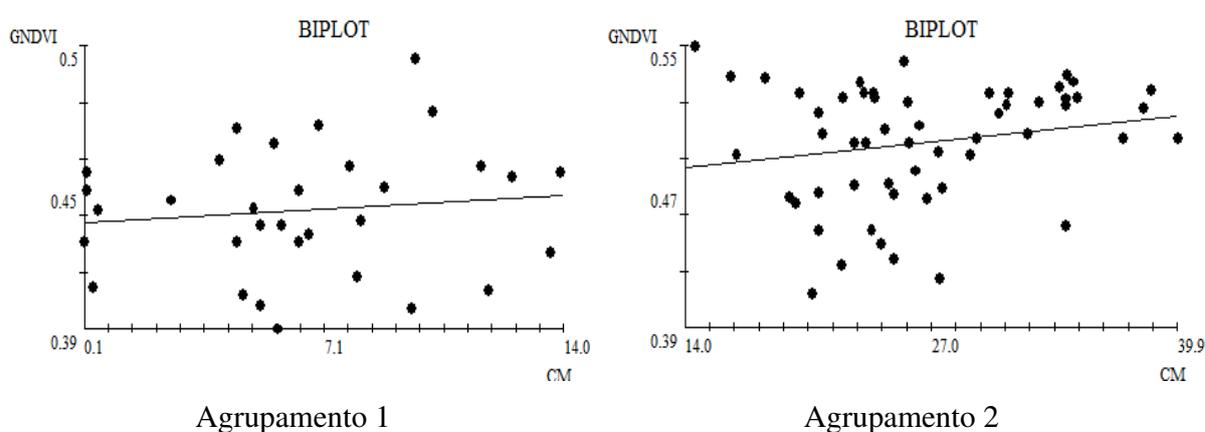


Figura 29. Gráfico de correlação GNDVI_CM dividido em dois, utilizando o valor 14 kg da variável CM como limite de corte.

Com a divisão do biplot em função dos dois grupos de pontos, a correlação reduziu 72 % (passando de 0,66 para 0,12) para os valores até 14 kg da variável CM (agrupamento 1) e 69 % (passando de 0,66 para 0,20) para os valores acima de 14 kg (agrupamento 2). Esta diminuição do coeficiente na correlação local, entre os IVs e a variável CM, esta em função da resolução espacial da imagem de satélite obtida. Portanto, no caso em estudo, para melhores resultados com a utilização de “janelas móveis” na aplicação da CoDSS_CCL, seria necessário à utilização de sensores com resolução espacial melhores que 20 m.

6.8 Considerações finais

A utilização de técnicas geoestatísticas possibilitou a identificação de zonas diferenciadas de manejo da cultura, com o variograma ajustado, apresentando alcance correspondente às dimensões médias dos talhões na área e o mapa de krigagem da variável apresentando alterações na produção de café em algumas regiões.

Na análise de correlação entre os IVs gerados, provenientes das imagens de satélites, ocorreu efeito de multicolinearidade para todos os índices testados, logo, os IVs foram abordados de forma univariada. A correlação dos índices com a variável CM foi em média de 0,6 para todos os IVs.

Os IVs ajustaram variogramas com mesmo modelo e alcance da variável primária (CM), confirmando assim uma alta correlação espacial, que ajudou a identificar a continuidade espacial característica como um processo isotrópico. O ajuste de variogramas para os IVs teve como finalidade apenas auxiliar na determinação da continuidade espacial da variável primária, já que sua utilização como imagem secundária nas simulações foi por meio da CoDSS colocada, sendo este método utilizado quando a variável secundária é conhecida em todos os pontos que pretendemos estimar.

as imagens simuladas apresentaram estatísticas, histograma e variografia semelhante aos dados amostrados em campo, da variável CM, para todos os métodos de simulação aplicados, atendendo aos pressupostos da DSS e CoDSS.

Os mapas de variância das simulações possibilitaram identificar regiões de incertezas na áreas de estudo onde a estimação e predição da variável CM são comprometidas. Essas regiões foram encontradas principalmente nas extremidades da área, com diminuição das incertezas a medida que se aproximavam dos pontos amostrados da variável primária. Para correção dessas incertezas o ideal seria aumentar a densidade dos pontos de amostragem nessas regiões.

A CoDSS colocada teve melhores resultados que aqueles apresentados pela DSS, evidenciando assim a utilização dos IVs como imagens secundárias. Na análise de quantificação a DSS teve a maior % de área de incerteza entre os métodos de simulação. Os IVs não apresentaram diferenças significativas entre si nos métodos de CoDSS.

A CoDSS_CCG apresentou menor área de incerteza associada a variável CM para todos os IVs utilizados, quando comparada com a CoDSS_CCL. Esse resultado foi em função do sensor das imagens de satélite utilizado, cuja resolução espacial de 20 m comprometeu os resultados com a utilização de “janelas móveis”.

7 CONCLUSÃO

A aplicação da geoestatística, simulação estocástica e do sensoriamento remoto em conjunto, possibilitou estimar e simular a produção do café conilon na área de estudo, identificando regiões de maior e menor produção, observação esta, útil, na geração de zonas de manejo, para obtenção de maior produtividade a custos menores nas próximas safras.

A identificação e quantificação da incerteza comprovou uma maior eficiência das estimações utilizando os índices de vegetação (IVs) como imagens secundárias, para a melhor predição da produção de café maduro.

8 REFERENCIAS BIBLIOGRÁFICAS

ALMEIDA, A.; JOURNEL, A. Joint simulation of multiple variables with a Markov-type correlogram model. **Mathematical Geology**, Montreal, v. 26, n. 5, p. 565-588, 1994.

BALASTREIRE, L. A. et al. Agricultura de precisão: mapeamento da produtividade de uma cultura de café. 2001. Disponível em:
<<http://www.gpsglobal.com.br/Artigos/Agricola/Cafe.html#07>>. Acesso em: 07 out. 2011.

BLAIS, R. A.; CARLIER, P. A. Applications of geostatistics in ore evaluation. **Ore Reserve Estimation and Grade Control**, Montreal, v. 9, p. 41-68, 1968.

BOURGAULT, G. Using non-Gaussian distributions in geostatistical simulations: **Mathematical Geology**, Montreal, v. 29, n. 3, p. 315-334, 1997.

BURGESS, T. M.; WEBSTER, R. Optimal interpolation and isarithmic mapping, of soil properties. I. The semivariogram and punctual kriging. **Soil Science Society of America Journal**, Madison, v. 31, p. 315-331, 1980a.

BURGESS, T. M.; WEBSTER, R. Optimal interpolation and isarithmic mapping, of soil properties. II. Block kriging. **Soil Science Society of America Journal**, Madison, v. 31, p. 333-341, 1980b.

CAERS, J. **Adding local accuracy to direct sequential simulation**. Stanford: Stanford Center for Reservoir Forecasting, 1999. v. 2.

CÂMARA, G.; MEDEIROS, J. S. Princípios básicos em geoprocessamento. In: ASSAD, E. D.; SANO, E. E. **Sistemas de informações geográficas: aplicações na agricultura**. 2. ed. Brasília, DF: Embrapa, 1998. p. 3-8.

- CAMARGO, E. C. G. **Desenvolvimento, implementação e teste de procedimentos geostatísticos (krigagem) no sistema de processamento de informações georreferenciadas (Spring)**. 1997. 123 f. Dissertação (Mestrado em Sensoriamento Remoto)- Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1997.
- CAMPOS, D. A. **Análise da variabilidade espacial da produtividade na cafeicultura de montanha com uso de técnicas de sensoriamento remoto**. 2005. 50 f. Dissertação (Mestrado em Engenharia Agrícola), Universidade Federal de Viçosa, Viçosa, MG, 2005.
- CAMPOS, P. M. et al. Uso da geotecnologia para o mapeamento da cultura do café no município de Ribeirão do Pinhal - Paraná. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. p. 3629-3634.
- CARVALHO, J. C. C. **Simulação estocástica para a calibração de imagens de satélite**. 2002. 91 f. Dissertação (Mestrado em Georrecursos)-Instituto Superior Técnico, Universidade Técnica de Lisboa, Lisboa, 2002.
- CMRP. **GeoMS - Geostatistical Modeling Software**. v. 1.0. Lisboa: IST, 2000.
- COSTA NETO, P. L. O. **Estatística**. 10. ed. São Paulo: Edgard Blücher, 1990. 264 p.
- CRESSIE, N. **Statistics for spatial data**. New York: John Wiley, 1991. 900 p.
- DAVID, M. **Geostatistical ore reserve estimation**. Amsterdam: Elsevier Publishing Company, 1977. 364 p.
- EASTMAN, J. R. **IDRISI Kilimanjaro for Windows: user's guide**. Version 15.0. Worcester: Clark University, 2006.
- EGUCHI, E. S. **Variabilidade espacial de atributos físico-hídricos de um solo hidromórfico no Município de Lavras, MG**. 2001. 85 f. Dissertação (Mestrado em Agronomia)-Universidade Federal de Lavras, Lavras, 2001.
- EMBRAPA. **Sistema brasileiro de classificação de solos**. 2 ed. Rio de Janeiro: Embrapa Solos, 2006. 3060 p.
- EPIPHANIO, J. C. N.; LEONARDI, L.; FORMAGIO, A. R. Relações entre parâmetros culturais e resposta espectral de cafezais. **Pesquisa Agropecuária Brasileira**, Brasília, DF, v. 29, n. 3, p. 439-447, 1994.
- EPIPHANIO, J. C. N. et al. Índices de vegetação no sensoriamento remoto da cultura do feijão. In: **Pesquisa Agropecuária Brasileira**, Brasília, DF, v. 31, n. 6, p. 445-454, 1996.

- FORMAGGIO, A. R.; ALVES, S. D.; EPIPHANIO, J. C. N. Sistemas de informações geográficas na obtenção de mapas de aptidão agrícola e de taxa de adequação de uso das terras. **Revista Brasileira de Ciência do Solo**, Campinas, v. 16, p. 249-256, 1992.
- GOLDEN SOFTWARE. **Surfer**: surface mapping system, version 8.00. Colorado: Golden Software Inc., 1993-2002. 1 CD-ROM.
- GOMEZ-HERNANDEZ, J.; JOURNEL, A. G. Joint sequential simulation of multigaussian fields, In: SOARES, A. (Ed.). **Geostatistics TROIA'92**. Dordrecht: Kluwer Academic, 1993. p. 85-94.
- GOOVAERTS, P. **Geostatistics for natural resources evaluation**. New York: Oxford University Press, 1997. 483 p.
- GUIMARÃES, E. C. Geoestatística básica e aplicada. In: UNIVERSIDADE FEDERAL DE UBERLÂNDIA. **Núcleo de estudos estatísticos e biométricos**. Uberlândia: UFU, 2004. 77 p.
- HAJRASULIHA, S. et al. Spatial variability of soil sampling for salinity studies in southwest Iran. **Irrigation Science**, Berlin, v. 1, p. 197-208, 1980.
- HOFFER, R. M. Biological and physical considerations in applying computer-aided analysis techniques to remote sensor data. In: SWAIN, P. H.; DAVIS, S. M. (Ed.). **Remote sensing: the quantitative approach**. New York: McGraw Hill, 1978. p. 227-265.
- HURTADO, S. M. C.; CARVALHO, L. M. T.; FERREIRA, E. Determinação das áreas cafezeiras através da análise multi-temporal de imagens de satélite, de 1997 e 1999. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11, 2003, Belo Horizonte. **Anais...** Belo Horizonte: INPE, 2003. p. 131-135.
- ISAAKS, E. H.; SRIVASTAVA, R. M. **Applied geostatistics**: introduction to applied geostatistics. Oxford: University Press, 1989. 561 p.
- JENSEN, J. R. **Sensoriamento remoto do ambiente**: uma perspectiva em recursos terrestres. São José dos Campos: Parêntese, 2009.
- JOURNEL, A. G.; HUIJBREGTS, C. J. **Mining geostatistics**. London: Academic Press, 1978. 600 p.
- JOURNEL, A. G. Modeling uncertainty: some conceptual thoughts, In: DIMITRAKOPOULOS, R. (Ed.). **Geostatistics for the next century**. Dordrecht: Kluwer Academic, 1994. p. 30-43.
- LEAL, J. C. G. **Mapeamento da produtividade na colheita mecanizada do café**. 2002. 74 f. Dissertação (Mestrado)-Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, 2002.

LIBARDI, P. L. et al. Variabilidade da umidade gravimétrica de um solo hidromórfico. **Revista Brasileira de Ciência do Solo**, Viçosa, MG, v. 20, n. 1, p. 1-12, 1996.

LOURENÇO, R. W.; LANDIM, P. M. B. Análise de regressão múltipla espacial. Texto Didático 13. Rio Claro: UNESP/IGCE, 2004. 34 p. Disponível em: <<http://www.rc.unesp.br/igce/aplicada>>. Acesso em: 12 abr. 2011.

LUCHIARI JUNIOR, A. et al. Strategies for establishing management zones for site specific nutrient management. In: INTERNATIONAL CONFERENCE ON PRECISION AGRICULTURE, 5. 2000, Bloomington. **Proceedings...** Bloomington: ASA/CSSA/SSSA, 2000.

LUIZ, S.; OLIVEIRA, C. G.; OKIDA, R. Comparação entre diferentes métodos de correção geométrica em imagem RADARSAT-1 no Flona Tapajós. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003. Belo Horizonte **Anais...** São José dos Campos: INPE, 2003. p. 325-332.

MANTOVANI, E. C.; QUEIROZ, D. M.; DIAS, G. P. Máquinas e operações utilizadas na agricultura de precisão. In: SILVA, F. M. **Mecanização e agricultura de precisão**. Poços de Caldas, 1998. p. 109 -158.

MATHERON, G. Principles of geostatistics. **Economic Geology**, Lancaster, v. 58. p. 1246-1266, 1963.

MATHERON, G. **The theory of regionalized variables and its application**. Paris: Ecole Nationale Supérieure des Mines de Paris. 1971. v. 5. 212 p.

MICROSOFT Excel, version 4.1: [S.l.]: Microsoft Corporation, 1998. 1 CD-ROM.

MOREIRA, M.A.; ADAMI, M.; RUDORFF, B.F.T. Análise do comportamento espectral de café em imagens do TM e ETM+ do Landsat-5 e 7. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte. **Anais...** Belo Horizonte: INPE, 2003. p. 189-196.

MOREIRA, M. A. et al. Geotecnologias para mapear lavouras de café nos estados de Minas Gerais e São Paulo. **Engenharia Agrícola**, Jaboticabal, v. 30, n. 6, p. 1123-1135, 2010.

MULLA, D. J. et al. A comparison of winter wheat yield and quality under uniform versus spatially variable fertilizer management. **Agriculture Ecosystems and Environment**, Amsterdam, v. 38, p. 301-311, 1992.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. 3. ed. São Paulo: Edgard Blücher, 2008. 388 p.

OLIVEIRA, R. B. et al. Variabilidade espacial do estado nutricional do cafeeiro canephora visando o manejo localizado. **Coffee Science**, Lavras, v. 5, mar. 2011. Disponível em: <<http://www.coffeescience.ufla.br/index.php/Coffeescience/article/view/337>>. Acesso em: 22 nov. 2012.

OLIVEIRA, R. B. **Mapeamento e correlação de atributos do solo e plantas de café Conilon para fins de agricultura de precisão**. 2007. 129 f. Dissertação (Mestrado em Agricultura)-Universidade Federal do Espírito Santo, Alegre, 2007.

PIMENTEL- GOMES, F. **Curso de estatística experimental**. 12. ed. Piracicaba: Nobel, 1987. 467 p.

PONZONI, F. J. Comportamento espectral da vegetação. In: MENESES, P. R.; NETTO, J. S. M. (Org.). **Sensoriamento remoto: refletância dos alvos naturais**. Brasília, DF: Ed. UNB, 2001. p. 157-199.

REZENDE, F. C. et al. Variabilidade espacial da condutividade elétrica em área com cafeeiro (*Coffea arabica* L.) adubado via fertirrigação e sistema tradicional. **Coffee Science**, Lavras, v. 6, set. 2011. Disponível em: <<http://www.coffeescience.ufla.br/index.php/Coffeescience/article/view/381>>. Acesso em: 22 nov. 2012.

RIBEIRO JUNIOR, P. J. **Métodos geoestatísticos no estudo da variabilidade espacial dos parâmetros do solo**. 1995. 99 f. Dissertação (Mestrado em Geoestatística) - Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, 1995.

RIZZI, R. **Geotecnologias em um sistema de estimativa da produção de soja: estudo de caso no Rio Grande do Sul**. 2004. 212 f. Tese (Doutorado em Sensoriamento Remoto)- Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2004.

ROCHA, J. V.; LAMPARELLI, R. A. C. Geoprocessamento. In: SILVA, F. M. **Mecanização e agricultura de precisão**. Poços de Caldas: UFAL/SBEA, 1998. p. 1-30.

ROSA, V. G. C. **Modelo agrometeorológico-espectral para monitoramento e estimativa da produtividade do café na Região Sul/Sudoeste do Estado de Minas Gerais**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2007. 143 p.

SALVIANO, A. A. C. **Variabilidade de atributos de solo e de *Crotalaria juncea* em solo degradado do município de Piracicaba-SP**. Piracicaba, 1996. 91 f. Tese (Doutorado em Agronomia) - Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, 1996.

SANCHEZ, R. B. et al. Variabilidade espacial de propriedades de latossolo e da produção de café em diferentes superfícies geomórficas. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 9, n. 4, p. 489-495, 2005.

SANTOS, C.; ALMEIDA, J. C. Caracterização de um índice de produtividade nos povoamentos de pinheiro-bravo em Portugal. **Finisterra: Revista Portuguesa de Geografia**, Lisboa, v. 38, n. 75, p. 51-65, 2003.

SILVA, A. P. **Variabilidade espacial de atributos físicos do solo**. 1988. 105 f. Tese (Doutorado em Agronomia)-Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, 1988.

SILVA, F. M. et al. Variabilidade espacial de atributos químicos e da produtividade da cultura do café em duas safras agrícolas. **Revista Ciência e Agrotecnologia**, Lavras, v. 32, n. 1, p. 231-241, jan./fev. 2008.

SILVA JÚNIOR, R. L. de. **Variabilidade espacial do índice de cone correlacionada com mapas de produtividade**. 2001. 132 f. Dissertação (Mestrado em Agronomia)-Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba, 2001.

SOARES, A. Classification of mining reserves using direct sequential simulation. In: LEUANGTHONG, O.; DEUTSCH, C.V. (Ed.). **Geostatistics banff**. Dordrecht : Springer, 2005. v. 1. p. 511-522.

SOARES, A. Direct sequential simulation and co-simulation. **Mathematical Geology**, Montreal, v. 33, n. 8, p. 911-926, 2001.

SOARES, A. **Geoestatística para as ciências da terra e do ambiente**. 2. ed. Lisboa: IST, 2006. 214 p.

SOARES, A. Sequential indicator simulation with correction for local probabilities. **Mathematical Geology**, Montreal, v. 30, n. 6, p. 761-765, 1998.

SOUSA, A. O. et al. Geoprocessamento e sensoriamento remoto como subsídio à previsão de safra de café no Extremo Oeste Baiano. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., Curitiba. **Anais...** São José dos Campos: INPE, 2011. p. 25.

SOUZA, L. C. de. **Variabilidade espacial da salinidade de um solo aluvial no semiárido paraibano**. 1999. 77 f. Dissertação (Mestrado em Engenharia Agrícola)-Universidade Federal da Paraíba, Campina Grande, 1999.

SOUZA, L. S. **Variabilidade espacial do solo em sistemas de manejo**. 1992. 162 f. Tese (Doutorado em Agronomia)-Universidade Federal do Rio Grande do Sul, Porto Alegre, 1992.

STAT SOFT. **Programa Statistica for Windows**, versão 7.0. Tulsa, 2001. 1 CD-ROM.

VALÉRIO FILHO, M.; PINTO, S. A. F. Imagens orbitais aplicadas ao levantamento de dados do meio físico: contribuição ao planejamento de microbacias hidrográficas. In: CONGRESSO

BRASILEIRO E ENCONTRO NACIONAL DE PESQUISAS SOBRE CONSERVAÇÃO DO SOLO, 8., Londrina, 1996. **Anais...** Londrina: IAPAR, 1996. p. 77-94.

VERLY, G. W. Sequential Gaussian cosimulation: a simulation method integrating several types of information. In: SOARES, A. (Ed.). **Geostatistics Troia**. Dordrecht: Kluwer, 1993. v. 1. p. 543-554.

VIEIRA, R. G. C.; LACERDA, M. P. C.; ALVES, H. M. R. Imagens orbitais aplicadas ao levantamento da cultura do café em Minas Gerais. In: SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL, 1., Poços de Caldas. **Anais...** Poços de Caldas: Embrapa Café; Minasplan, 2000b. p. 86-89.

VIEIRA, S. R. et al. Geostatistical theory and application to variability of some agronomical properties. **Hilgardia**, Berkeley, v. 51, n. 3, p. 1-75, 1983.

VIEIRA, S. R. Geoestatística aplicada à agricultura de precisão. In: _____. **GIS Brasil'98**. Curso... Curitiba. [s.n.], 1998. 53 p.

VIEIRA, S. R. **Geoestatística**: curso de extensão universitária. Botucatu: UNESP, 1996. 166 p.

VIEIRA, S. R. Geoestatística em estudos de variabilidade espacial do solo. In: NOVAIS, R. F.; ALVAREZ V., V. H.; SCHAEFER, C. E. G. R. (Ed.). **Tópicos em ciência do solo**. Viçosa, MG: Sociedade Brasileira de Ciência do Solo, 2000a. v. 1. p. 1- 54.

VIEIRA, T. G. C.; ALVES, H. M. R.; LACERDA, M. P. C. Parâmetros culturais para avaliação do comportamento espectral da cultura do café (*Coffea arabica*) em Minas Gerais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003. Belo Horizonte. **Anais...** São José dos Campos: INPE, 2003. p. 247-254.

WEBSTER, R. Quantitative spatial analysis of soil in field. **Advances in Soil Science**, New York, v. 3, p. 2-53, 1985.